

Metody pro registraci medicínských obrazů – laboratorní úloha

Methods for Medical Image Registration – a Laboratory Task

Eliška Szalbotová

Bakalářská práce

Vedoucí práce: Ing. Jan Kubíček, Ph.D.

Ostrava, 2021

Abstrakt:

Bakalářská práce je zaměřena na zpracování reálných lékařských obrazových dat. První část práce se zabývá procesem pořízení a zpracování obrazu, metodami segmentace obrazu a především registrací obrazu, jejími metodami a aplikacemi. V práci je definován postup registrace a různá hlediska klasifikace registračních metod, základní typy transformací, interpolací a metrik podobnosti. Druhá část práce popisuje implementaci vybraných metod registrace na reálných sadách snímků. Cílem bakalářské práce je nalezení optimálních parametrů transformace. První implementací je registrace založená na rotaci, jejímž úkolem je zjištění optimálního úhlu otočení plovoucího snímku. Druhým výstupem práce je nalezení optimální kombinace vstupních parametrů pro registraci založenou na intenzitě. Třetím výstupem jsou laboratorní úlohy sloužící pro výukové účely. Laboratorní úlohy jsou založeny na úkolech v praktické části práce. Testování metod probíhalo v prostředí MATLAB R2018b společnosti MathWorks. Výsledky metod byly zpracovávány v excelu.

Klíčová slova:

zpracování obrazu, registrace obrazu, registrace založená na rotaci, registrace založená na intenzitě

Abstract:

The bachelor thesis is focused on the processing of real medical image data. The first part of the thesis deals with the process of image acquisition and processing, image segmentation methods and especially image registration, registration methods and applications. The registration process, various aspects of the classification of registration methods, basic types of transformations, interpolations and similarity metrics are defined in the thesis. The second part of the thesis describes the implementation of selected registration methods on real dataset. The aim of the bachelor thesis is to find the optimal parameters of the transformation. The first implementation is rotation based registration. The task of this type of registration is to determine the optimal rotation angle of the floating image. The second output of the thesis is to find the optimal combination of input parameters for registration based on intensity. The third output are laboratory tasks used for educational purposes. Laboratory tasks are based on tasks in the practical part of the work. Testing of the methods took place in the MATLAB R2018b by MathWorks. The method results were processed in Excel.

Key words:

image processing, image registration, rotation based registration, intensity based registration

Ráda bych na tomto místě poděkovala Ing. Janu Kubíčkoví, Ph.D. za odborné vedení práce, trpělivost, cenné připomínky a čas, který mi při zpracování bakalářské práce věnoval. V neposlední řadě děkuji své rodině za podporu během celé délky studia.

Obsah

Seznam použitých zkratk a symbolů	6
Seznam obrázků	9
Seznam tabulek.....	11
Úvod.....	12
1 Zpracování biomedicínských obrazových dat	13
1.1 Proces zpracování obrazu	13
1.1.1 Pořízení obrazu a digitalizace.....	13
1.1.2 Předzpracování obrazu	17
1.1.3 Segmentace	17
1.1.4 Popis objektů	17
1.1.5 Klasifikace	17
1.2 Registrace obrazu	18
1.3 Datové formáty pro obrazová data.....	19
2 Segmentace zájmových struktur	20
2.1 Práhování.....	20
2.1.1 Otsu metoda	20
2.1.2 Rosenfeldova, Sezanova a Rameshova metoda	21
2.1.3 Procentuální práhování.....	21
2.2 Pixelová klasifikace	21
2.2.1 Riddlerova metoda	21
2.2.2 Lloydova metoda a Kittlerova metoda	22
2.3 Hranově orientovaná segmentace.....	23
2.3.1 Metody založené na první derivaci	23
2.3.2 Metody založené na druhé derivaci.....	24
2.4 Regionově orientovaná segmentace	25
2.4.1 Segmentace růstem oblastí	26
2.4.2 Segmentace dělením oblastí.....	27
2.4.3 Segmentace dělením a slučováním oblastí	27
2.5 Metoda Watershed.....	27
2.6 Metody umělé inteligence	28
2.6.1 Strojové a hluboké učení	29
2.6.2 Sémantická segmentace	30
3 Základní principy registrace obrazu	31
3.1 Postup registrace obrazu	31

3.2	Interpolace	32
3.3	Problematika registrace obrazu	32
3.3.1	Metriky podobnosti	32
3.4	Klasifikace registrace obrazu	33
3.4.1	Registrace podle její aplikace	33
3.4.2	Registrace podle počtu parametrů	33
3.4.3	Registrace podle devíti kritérií	34
4	Rešerše aplikací registrace obrazu	39
4.1	Registrace na základě segmentace obrazu a symetrické soběpodobnosti	39
4.2	Metoda registrace obrazu maximalizací vzájemných informací	40
4.3	Registrace multimodálních mozkových obrazů na základě optického toku	41
4.4	Rigidní registrace obrazu založená na očekávané hodnotě maximalizace	42
5	Implementace registračních algoritmů a testování na reálných datech	44
5.1	Dostupné algoritmy v MATLABu	44
5.1.1	Interaktivní registrace pomocí aplikace Registration Estimator	45
5.1.2	Automatická registrace založená na intenzitě	46
5.1.3	Registrace založená na řídících bodech	48
5.1.4	Automatická registrace pomocí detekce a přiřazení funkce/vlastnosti	48
5.1.5	Další funkce v MATLABu	49
5.2	Evaluační techniky	49
5.3	Registrace obrazu pomocí rotace	51
5.3.1	Detailní popis úlohy	53
5.4	Implementace registrace založené na intenzitě	54
5.4.1	Metrika podobnosti	55
5.4.2	Optimalizátor	55
5.4.3	Detailní popis úlohy	57
5.4.4	Proces MATLABu	59
6	Analýza výsledků	60
6.1	Výsledky registrace pomocí rotace	60
6.2	Výsledky registrace založené na intenzitě	64
7	Diskuze a vyhodnocení výsledků práce	69
	Závěr	71
	Seznam literatury	73
	Seznam příloh bakalářské práce	78

Seznam použitých zkratek a symbolů

b	Bit
BCFCM	Bias Corrected Fuzzy C-means, korekce zkreslení fuzzy C-means shlukováním
BMP	Windows Bitmap, bitová mapa, formát pro rastrovou grafiku
BRISK	Binary Robust Invariant Scalable Keypoints
CC (-, %)	Correlation Coefficient, korelační koeficient
CT	Computed Tomography, výpočetní tomografie
DICE coefficient	Koeficient podobnosti dvou vzorků
DICOM	Digital Imaging and Communication in Medicine, datový standard pro přenos a uložení medicínských obrazových dat
EM	Expectation Maximization, očekávaná hodnota maximalizace
FAST	Features from Accelerated Segment Test
FCM	Fuzzy C-means, fuzzy C-means shlukování
GB	Gigabyte
GF	Growth Factor, růstový faktor
GIF	Graphics Interchange Format, formát pro rastrovou grafiku
IR	Initial Radius, počáteční poloměr poloměru vyhledávání
JPEG	The Joint Photographics Experts Group, formát pro rastrovou grafiku
LoG	Laplacian of Gaussian, Laplacián Gaussiánu
MaxI	Maximum Iterations, maximální počet iterací
MB	Megabyte
MI	Mutual Information, vzájemná informace
MMI	Mattes Mutual Information, Mattesova vzájemná informace
MRI	Magnetic Resonance Imaging, magnetická rezonance
MSE (-)	Mean-squared Error, střední kvadratická chyba
MSER	Maximally Stable Extremal Regions
MSR	Mirror Symmetry via Registration, metoda zrcadlové symetrie
max	Maximum
min	Minimum
miLBP	modality-independent Local Binary Pattern, modálně nezávislý binární deskriptor
NHB	Number of Histogram Bins, počet intervalů histogramu

NSS	Number of Spatial Samples, počet prostorových vzorků
ORB	Oriented FAST and Rotated BRIEF
PACS	Picture Archiving and Communication System, systém umožňující správu obrazové dokumentace
PD	Proton-denzitní obraz
PDF	Portable Document Format, formát pro vektorovou grafiku
PDIST (-)	Pairwise Distances, Euklidovská vzdálenost
PET	Positron Emission Tomography, pozitronová emisní tomografie
PNG	The Portable Network Graphics, formát pro rastrovou grafiku
RGB	Red, Green, Blue, barevný model červená, zelená, modrá
RSSD	Robust Self-similarity Deskriptor, robustní deskriptor soběpodobnosti
RTG	Rentgen, rentgenové vyšetření
SPECT	Single Photon Emission Computed Tomography, jednofotonová emisní výpočetní tomografie
SSC	Self-Similarity Context, kontext soběpodobnosti
SSD	Sum of Squared Differences, součet rozdílů čtverců, střední kvadratická chyba
SSIM (-, %)	Structural Similarity, strukturální podobnost
SURF	Speeded up Robust Features
T1	Čas, za který dojde k obnovení podélného vektoru magnetizace na 63 %
T2	Čas, za který dojde k poklesu příčného vektoru magnetizace na 37 %
TIFF	Tag Image File Format, formát pro rastrovou grafiku
UI	Umělá inteligence
UP	Use all Pixels, zahrnutí pixelů do výpočtu metrik
US	Ultrasound, ultrazvukové vyšetření
2D	Dvojměrný
3D	Trojměrný
4D	Čtyřměrný
∇f	Gradient funkce f
θ	Úhel
\tan^{-1}	Inverzní funkce k funkci tangens
μ, \bar{x}	Průměr
$\partial_x f$	Parciální derivace funkce f k proměnné x

σ	Směrodatná odchylka
°	Stupeň
%	Procento
mm	Milimetr

Seznam obrázků

Obrázek 1: Jednotlivé kroky procesu zpracování obrazu, s využitím zdroje [5].	13
Obrázek 2: Blokové schéma digitalizace obrazu [3].	14
Obrázek 3: Snímky hrudníku dle prostorového rozlišení, A: 256x256; B: 128x128; C: 32x32; D: 16x16 [8].	15
Obrázek 4: Kvantování – bitová hloubka určuje rozlišení kontrastu obrazu [8].	16
Obrázek 5: Snímky hrudníku dle kvantizační úrovně, A: 8 bitů; B: 4 bity; C: 2 bity; D: 1 bit [8].	16
Obrázek 6: Znárodnění postupu klasifikace, s využitím zdrojů [5][9].	17
Obrázek 7: Histogram snímku, princip Otsu metody, upraveno [8].	20
Obrázek 8: Segmentace prahováním, práh 0,4, vlevo originální obraz, vpravo výsledek segmentace [12].	21
Obrázek 9: Prahování sítnice Lloydovou metodou [14].	22
Obrázek 10: Prahování sítnice Kittlerovou metodou [14].	22
Obrázek 11: Detail hrany při hranové segmentaci, zobrazení derivací [15].	23
Obrázek 12: Srovnání hranových operátorů, A: originální obraz; B: Cannyho; C: LoG; D: Robertsův; E: Prewittové; F: Sobelův, upraveno [19].	25
Obrázek 13: Regionově orientovaná segmentace, vlevo originální obraz, vpravo výsledek segmentace [12].	26
Obrázek 14: Metoda Watershed, vlevo originální obraz, vpravo výsledek segmentace [12].	27
Obrázek 15: Model neuronu, upraveno [20].	28
Obrázek 16: Propojení mezi vrstvami v neuronové síti, upraveno [22].	28
Obrázek 17: Rozdíl mezi strojovým a hlubokým učením při segmentaci, upraveno [22].	29
Obrázek 18: Sémantická segmentace, upraveno [23].	30
Obrázek 19: Jednotlivé kroky registrace [27].	31
Obrázek 20: Metody registrace, zdroj vlastní.	34
Obrázek 21: Druhy transformací, upraveno [26].	37
Obrázek 22: Histogramová specifikace: (a) referenční obraz a jeho histogram; (b) plovoucí obraz a jeho histogram; (c) výsledný obraz s histogramem [30].	41
Obrázek 23: Výsledky studie: (a) plovoucí obraz; (b) referenční obraz; (c) metoda založená na optickém toku a SURF; (d) metoda založená na démonech; (e) metoda SURF; (f) metoda MI [30].	42
Obrázek 24: Ukázka aplikace [43].	46
Obrázek 25: Postup registrace obrazu, zkompletováno na základě zdrojů [36][44].	47
Obrázek 26: Výběr řídicích bodů [46].	48
Obrázek 27: Vyznačené body [47].	49
Obrázek 28: Ukázka SSIM, snímek klíční kosti, zdroj vlastní.	51
Obrázek 29: Popis sítnice, zdroj vlastní.	52
Obrázek 30: Vývojový diagram úlohy, zdroj vlastní.	53
Obrázek 31: Rotace snímku, vlevo referenční obraz, vpravo plovoucí obraz s úhlem otočení 60 stupňů, zdroj vlastní.	54
Obrázek 32: Vývojový diagram úlohy, zdroj vlastní.	57
Obrázek 33: Vývojový diagram postupu v MATLABu, zdroj vlastní.	59

Obrázek 34: Grafická závislost evaluačních hodnot jednoho referenčního a transformovaného plovoucího obrazu, zdroj vlastní.....	60
Obrázek 35: Registrace obrazu v detailu, zdroj vlastní.	62
Obrázek 36: Registrace snímků s nejlepšími hodnotami evaluačních technik. Registrace a) referenční snímek č. 1, plovoucí snímek č. 1; b) referenční snímek č. 1, plovoucí snímek č. 2; c) referenční snímek č. 3, plovoucí snímek č. 1; d) referenční snímek č. 5, plovoucí snímek č. 2, zdroj vlastní.	62
Obrázek 37: Registrace snímků s nejhoršími hodnotami evaluačních technik. Registrace a) referenční snímek č. 2, plovoucí snímek č. 1; b) referenční snímek č. 2, plovoucí snímek č. 7; c) referenční snímek č. 2, plovoucí snímek č. 6; d) referenční snímek č. 6, plovoucí snímek č. 1, zdroj vlastní.	63
Obrázek 38: Krabicové grafy s kombinacemi před korekcí, zdroj vlastní.	64
Obrázek 39: Krabicové grafy s kombinacemi po korekci, zdroj vlastní.	65
Obrázek 40: Grafické zobrazení Top indexu, zdroj vlastní.	66
Obrázek 41: Krabicové grafy s rozložením evaluačních hodnot, zdroj vlastní.	67
Obrázek 42: Závislost evaluačních technik, zdroj vlastní.	67
Obrázek 43: Aplikace optimálního nastavení na snímky retiny, zdroj vlastní.	68
Obrázek 44: Aplikace optimálního nastavení na RTG snímky, zdroj vlastní.	68
Obrázek 45: Aplikace optimálního nastavení na RTG snímky femuru, zdroj vlastní.	68
Obrázek 46: Snímky retiny, první dataset.....	II
Obrázek 47: Snímky retiny, druhý dataset.	III
Obrázek 48: RTG snímky, třetí dataset.	IV

Seznam tabulek

Tabulka 1: Přehled vlastností obrazových formátů [1]	19
Tabulka 2: Tabulka funkcí, které jednotlivé řešení registrace nabízejí [40]	44
Tabulka 3: Metriky a optimalizátory [45]	47
Tabulka 4: Hodnoty tvořící kombinace vstupních parametrů, zdroj vlastní	58
Tabulka 5: Hodnoty tvořící kombinace vstupních parametrů po korekci, zdroj vlastní	58
Tabulka 6: Tabulka vybraných hodnot, zdroj vlastní	61
Tabulka 7: Tabulka nejlepších hodnot, zdroj vlastní	61
Tabulka 8: Tabulka nejhorších hodnot, zdroj vlastní	63
Tabulka 9: Ukázka deseti kombinací parametrů, zdroj vlastní	64
Tabulka 10 :Optimální nastavení, zdroj vlastní	66
Tabulka 11: Výsledné hodnoty evaluací, zdroj vlastní	66
Tabulka 12: Tabulka vyřazených hodnot, zdroj vlastní	69

Úvod

Zrak je důležitým smyslem informujícím mozek o okolním prostředí. Světelné paprsky se odráží od věcí kolem nás a dopadají na sítnici oka. Na sítnici dochází k přeměně energie světla na elektrické impulzy, které jsou zrakovým nervem dovedeny do zrakového centra v mozku, kde je obraz ze sítnice rekonstruován. Touha uchování cenných i každodenních obrazových momentů přispěla k rozvoji malířství, později k vynalezení fotoaparátu a rozmachu počítačového zpracování obrazu. Nástup digitalizace a rozvoj lékařských zobrazovacích technologií dosáhl v minulých letech obrovského rozmachu. Výpočetní technika se stala nedílnou součástí mnoha oblastí medicíny. Přístroje pomáhají detekovat a lokalizovat patologické útvary a lékaři mohou včas zahájit nejefektivnější léčbu. Existuje velké množství zobrazovacích technik, která dovolí nahlédnout do těla pacienta, aniž by musel být operován. Pomocí zobrazovacích systémů je snímána patologická tkáň, jejíž obraz je dále zpracován a upraven tak, aby byly získány poznatky na první pohled špatně viditelné. Metody zpracování obrazu umožňují ostření objektů, filtraci pozadí, jasové transformace a prostorové rekonstrukce obrazu patologického útvaru.

Obrazy vznikají pomocí senzorů jednotlivých zobrazovacích technik. Za účelem zpracování výpočetní technikou je obraz převeden ze spojitého signálu do digitální podoby. Při nevhodných podmínkách pořízení obrazu je velmi pravděpodobné jeho zkreslení, proto je nutné digitální obraz předzpracovat, např. upravit jas a kontrast. Hojně využívaným krokem zpracování obrazů je segmentace, kdy dochází k vyčlenění oblastí zájmů. Následuje popis segmentovaných objektů za účelem klasifikace do tříd se společnými rysy.

K porovnání informací z více obrazů nebo z různých zobrazovacích technik slouží registrace obrazu. Registrace obrazu je založená na hledání vhodné transformace jednoho snímku tak, aby byl s druhým maximálně podobný. V medicíně je využívána zejména při snímcích z CT a MRI, kdy dochází k získání úplnějších informací o pacientovi, protože CT zobrazuje hutnou tkáň, zatímco MRI měkké tkáně. Snímky vstupující do procesu registrace většinou zobrazují stejnou scénu, ale jsou pořízeny v různém čase, z různých pohledů nebo v různých modalitách. Tímto způsobem registrace obrazu umožňuje například ověřit úspěšnost léčby, růst nádoru nebo srovnat údaje pacienta s anatomickými atlasy.

V práci je popsán proces zpracování obrazu, metody segmentace obrazu a především metody registrace. Proces registrace zahrnuje široké spektrum metod, jejichž kombinace závisí na typu deformace snímků a modalitě snímku. Práce se zabývá registrací založenou na geometrické transformaci a registrací založenou na intenzitě.

Cílem práce je implementovat zmíněné registrační metody na reálná medicínská data. V případě registrace geometrickou transformací je úkolem navrhnout iterační cyklus, který pomocí daných funkcí MATLABu zjistí míru podobnosti obrazů při jednotlivých úhlech otočení. Výsledkem je optimální úhel otočení plovoucího obrazu. Dalším cílem práce je nalezení optimálních vstupních parametrů registrace založené na intenzitě a následná implementace optimálního nastavení na obrazová data.

1 Zpracování biomedicínských obrazových dat

Obraz je zrakový vjem vznikající dopadem světla na sítnici oka, kde je vnímáno spektrální složení a intenzita světla. Za obraz je pokládána rovina pokrytá bodovými zdroji světla promítnutá právě na sítnici. Pokud je uvedena úvaha matematicky formulována, tak je obraz definován jako funkce dvou proměnných přiřazující každému bodu hodnotu, která definuje barevné vlastnosti. Rovinu si lze představit jako matici, jejíž prvky reprezentují barevné vlastnosti obrazu. V této kapitole bude rozebrán postup zpracování digitálního obrazu [1].

Obraz může vznikat také pomocí snímacích čipů, které jsou součástí nejrůznějších zařízení. Výpočetní technika se stala nedílnou součástí lékařského prostředí a napomáhá k lepší vizualizaci snímané scény. Mezi typické představitele zobrazovacích systémů patří RTG¹, MRI², CT³, PET⁴, SPECT⁵, US⁶, mikroskopické a infrazobrazovací systémy [2][3][4].

1.1 Proces zpracování obrazu

Obraz je spojitá veličina. Aby mohlo být s obrazem dále manipulováno (ukládání, přenos, modifikace) a mohl být zpracován výpočetní technikou, je zapotřebí převést spojitý signál do digitální podoby. Možnosti zpracování obrazu záleží na vlastnostech výpočetní techniky a použití jednotlivých kroků je závislé na aplikaci. Zpracování signálu se dělí do několika kroků [2][3].



Obrázek 1: Jednotlivé kroky procesu zpracování obrazu, s využitím zdroje [5].

1.1.1 Pořízení obrazu a digitalizace

Pořízení neboli akvizice obrazových dat je inicializační operací a ovlivňuje kvalitu obrazu. Vstupní informací může být jas z kamery, intenzita rentgenového záření, tepelné záření nebo ultrazvuk [5].

Druhou operací je digitalizace. Spojitý analogový signál se pomocí digitalizačního zařízení (např. scanner⁷, frame grabber⁸) převede na diskrétní digitální signál. Spojitá obrazová funkce $f(x, y)$ poté odpovídá digitální diskrétní funkci $f(i, j)$. Obraz je získán vzorkováním do matice $M \times N$ bodů, která představuje počet pixelů obrazu, a kvantováním do K úrovní, které odpovídají jasu v původní obrazové funkci [6].

¹ RTG – Rentgen, rentgenové vyšetření.

² MRI – Magnetic Resonance Imaging, magnetická rezonance.

³ CT – Computed Tomography, výpočetní tomografie.

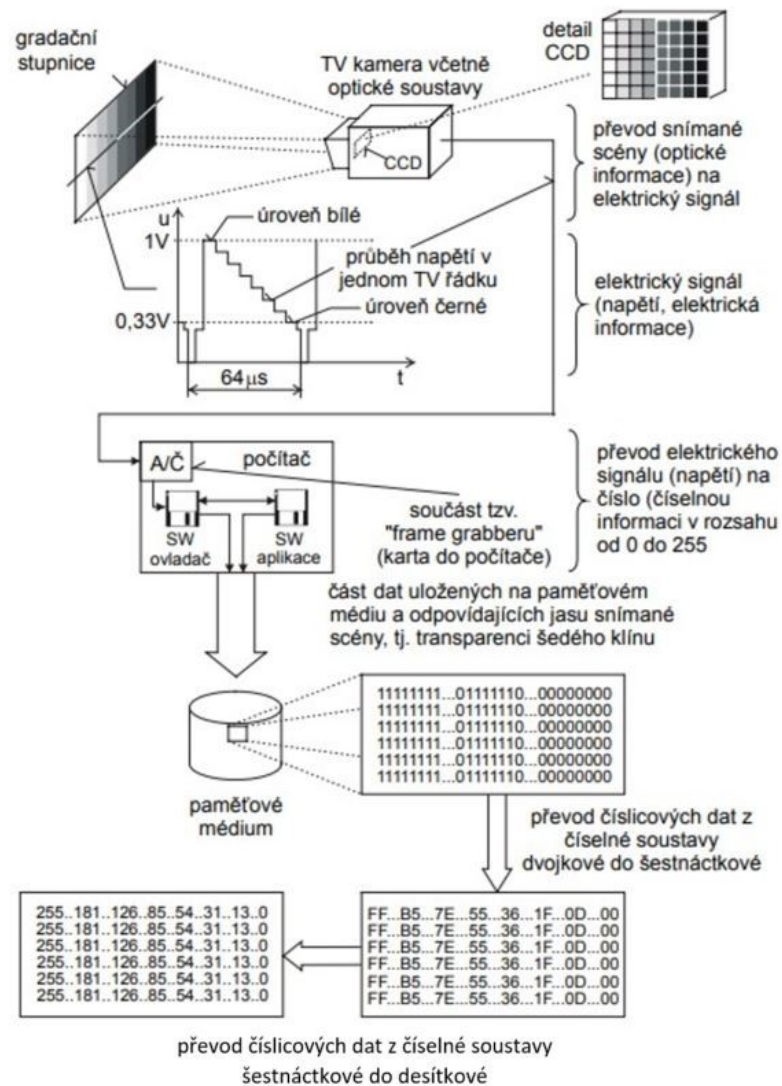
⁴ PET – Positron Emission Tomography, pozitronová emisní tomografie.

⁵ SPECT – Single Photon Emission Computed Tomography, jednofotonová emisní výpočetní tomografie.

⁶ US – Ultrasound, ultrazvukové vyšetření.

⁷ Skener – digitalizační zařízení používané k převodu fotografií do číslicové podoby.

⁸ Digitalizační karta – digitalizační zařízení používané k převodu videí do číslicové podoby.




Obrázek 2: Blokové schéma digitalizace obrazu [3].

Vzorkování

Vzorkování je proces, během kterého získáváme ze spojitě obrazové funkce úzké impulsy, jejichž amplitudy odpovídají analogovému signálu v určitých časových okamžicích. Pro teoretické úvahy se při vzorkování používá nekonečně úzký a nekonečně vysoký teoretický signál, tzv. Diracův impuls. Vzorkovaný obraz si lze poté představit jako dvourozměrné pole tvořené Diracovými impulsy, které odpovídají diskretním hodnotám obrazu. Vzorkování vyplývá z platnosti Shannon-Kotělnikova teorému, který říká, že vzorkovací frekvence je větší než dvojnásobek maximální frekvence vzorkovaného signálu. Pokud je dodržen tento teorém při vzorkování signálu, nevznikne podvzorkování neboli aliasing. Aliasing je úplné a nenávratné zkreslení signálu. Při nízké vzorkovací frekvenci je nízké i rozlišení obrazu a informace detailů v obrazu se ztrácí. Naopak při velmi vysoké frekvenci roste výsledné rozlišení a výpočetní náročnost [3][5][6]. U medicínských signálů je vzorkovací frekvence 4–5 vyšší než maximální frekvence [7].


Obrázek 3 ukazuje rentgenový snímek hrudníku, kde obrázek A je dobře čitelný pro vizuální reprezentaci. Naopak snímek D má nízké rozlišení.




Obrázek 3: Snímky hrudníku dle prostorového rozlišení, A: 256x256; B: 128x128; C: 32x32; D: 16x16 [8].

Kvantování

Jas skutečného obrazu je převeden na hodnotu elektrického napětí. Elektrické napětí je přímo úměrné jasu. Tzn., že při snímání ve tmě je napětí téměř nulové a při snímání světlé expozice je hodnota napětí maximální. Při kvantování dochází k převodu amplitud signálu na číslcový tvar a tím přiřazení diskrétní hodnoty, tedy úrovně K . Pro reprezentaci informace obrazového elementu je použito b bitů. Poté počet úrovní $K = 2^b$. Pokud není počet úrovní K dostatečný, dochází ke zkreslení obrazu a vzniku nepřesností. Standardní rozsah úrovní K je 256, což odpovídá 2^8 bitů. V obrazové matici jsou pixely v rozsahu hodnot $\langle 0; 255 \rangle$ [3][5][6].



Obrázek 4: Kvantování – bitová hloubka určuje rozlišení kontrastu obrazu [8].



Obrázek 5: Snímky hrudníku dle kvantizační úrovně, A: 8 bitů;
B: 4 bity; C: 2 bity; D: 1 bit [8].

Obrázek 5 ukazuje opět rentgenový snímek hrudníku s rozdílnými kvantizačními úrovněmi. Obrázek A zobrazuje vysokou kvantizační úroveň, obrázek D naopak úroveň nejnižší.

1.1.2 Předzpracování obrazu

Po získání digitálního obrazu následuje předzpracování obrazu. Vlivem špatného snímání a nevhodných okolních podmínek může být obraz zkreslený. Cílem předzpracování obrazu je tyto nedostatky odstranit, vylepšit obraz pro další použití a zvýraznit detaily obrazu [5].

Základní rozdělení metod předzpracování obrazu:

- jasová transformace – úprava jasu a kontrastu,
- geometrická transformace – prostorové deformace, pootočení obrazu,
- filtrace a ostření – potlačení šumu, vyhlazování, ostření [5].

1.1.3 Segmentace

Dalším krokem zpracování obrazu je segmentace. Jedná se o jeden z nejdůležitějších a nejtěžších postupů, kdy dochází k vyčlenění částí obrazu, tzv. oblastí zájmů. Jsou to oblasti složené z pixelů podobného jasu a barvy. Vyčlenění zajistí další práci pouze s určitými částmi obrazu, které zobrazují nejdůležitější informaci. Mezi hlavní segmentační techniky patří prahování, pixelová klasifikace, hranově orientovaná segmentace, regionově orientovaná segmentace a metody umělé inteligence (UI) [3][4][6].


Rozdělení segmentačních technik se na jednotlivých zdrojích různí. Zde je uvedeno dělení ze zdroje [4], neboť je srozumitelné a smysluplné. Segmentační techniky budou podrobněji rozebrány v kapitole 2.

1.1.4 Popis objektů

Cílem je popsat objekty na základě příznaků nalezené segmentací, aby mohly být v dalším kroku pomocí klasifikátorů rozděleny do příslušných tříd neboli skupin se společnými rysy. Objekty se charakterizují tak, aby je následný klasifikační algoritmus na základě popisu rozpoznal. Popis může být kvalitativní nebo kvantitativní. Kvalitativní popis zobrazuje tvarové vlastnosti objektů a vzájemný vztah mezi nimi. Popis kvantitativní je vyjádřen číselnou charakteristikou, např. velikostí oblasti nebo počtem vyčleněných objektů [5][9].

1.1.5 Klasifikace

Závěrečná operace zpracování obrazu je klasifikace. Jedná se o postup, kterým jsou popsané objekty automaticky roztříděny do tříd. Rozdělení do tříd závisí na klasifikačním algoritmu, který rozhoduje o rozdělení na základě popisu objektů. Způsob popisu tvoří vstup do klasifikátoru [5][9].



Obrázek 6: Znárodnění postupu klasifikace, s využitím zdrojů [5][9].

Existují dva hlavní druhy klasifikátorů, příznakové a syntaktické. Příznakové klasifikátory využívají kvantitativní popisy, kdy jsou vstupní data vyjádřena vektorem hodnot charakterizujícím daný objekt [5][9]. Příznak je určitá číselná veličina charakterizující objekt. Tato veličina odlišuje jednotlivé třídy. Existují čtyři základní typy příznaků – spektrální, prostorové, časové a polarizační. Spektrální příznaky vyjadřují hodnoty intenzity obrazu. Prostorové příznaky jsou tvořeny plošnou homogenitou, která určuje hranice objektu, a parametry vyjadřujícími texturu objektu. Změny spektrálních a prostorových příznaků v čase zkoumají časové příznaky [10]. Pokud třídy neexistují a objekty projevují přirozenou tendenci seskupení, pak se využívá shlukovací analýzy. Jejím úkolem je nalézt homogenní shluky objektů tak, aby objekty shluku měly podobné vlastnosti, ale zároveň měly co nejméně podobných vlastností s objekty mimo tento shluk. Shlukování snižuje počet dimenzí objektu a příslušnost objektu ke skupině je definována pouze jedinou proměnnou. Syntaktické klasifikátory jsou popsány primitivy, které rozdělují objekty na základě jejich struktury a využívají tedy kvalitativního popisu. K popsání slouží abeceda, gramatika jednotlivých tříd a jazyk popisu [5][9].

Cílem klasifikace je rozhodnutí o charakteru objektu, posouzení kvality objektu a rozhodnutí o budoucnosti objektu. V biomedicině se může jednat např. o určení dané tkáně, posouzení, zda je daná tkáň v pořádku, nebo nikoliv, a navržení případné léčby [5][9].

1.2 Registrace obrazu

Proces registrace je založený na nalezení vhodné transformace jednoho obrazu tak, aby se v určitém smyslu podobal druhému obrazu. Registrace obrazu je důležitým krokem při zpracování obrazů, kdy je nutné integrovat, nebo porovnat informace z více obrazů. Během pořízení obrazů mohou vznikat umělé rozdíly způsobené například pohybem. Cílem registrace je artefakty odstranit a zachovat pouze rozdíly týkající se sledovaného objektu [11].

Metody registrace obrazu se klasifikují do skupin dle několika kritérií. Prvním dělením je registrace založená na intenzitě a registrace založená na význačných rysech. Registrace obrazu založená na intenzitě zahrnuje informace z celého obrazu a srovnávají intenzitu v jednotlivých obrazech. Metody založené na význačných rysech hledají souvislosti mezi rysy obrazu, jako jsou čáry, body a hrany. Další dělení je podle způsobu transformace obrazu. Mezi rigidní transformace patří rotace, translace a změna měřítko. Pružné, poddajné, transformace jsou schopny lokální transformace obrazu. Posledním dělením, zde uvedeným, jsou parametrické a neparametrické metody registrace. Parametrické metody využívají k registraci význačné body obou obrazů, hlavní osy nebo lineární registraci. Neparametrické metody hledají transformaci na základě minimalizace míry vzdálenosti [11]. Další možná dělení registrace obrazu jsou uvedena např. ve zdrojích [25][27].

Registraci obrazu je věnována kapitola 3.

1.3 Datové formáty pro obrazová data

Pro uložení obrazových dat je využíváno několik datových formátů, které jsou rozděleny na nekomprimované a komprimované. Komprimované obrazy lze komprimovat bezztrátovými nebo ztrátovými algoritmy. Dále datové formáty mohou být děleny na rastrové a vektorové. U vektorových formátů je informace v obraze popsána matematicky. Vektorový formát je například formát PDF⁹. V rastrových formátech je obraz reprezentován množinou pixelů. Mezi tyto formáty řadíme například formát BMP¹⁰, JPEG¹¹, PNG¹², GIF¹³, TIFF¹⁴ a DICOM¹⁵ [1][8].

- Formát BMP neobsahuje většinou žádnou kompresi a není vhodný pro sdílení dat.
- Nejrozšířenějším bezztrátovým formátem je formát PNG.
- Formát JPEG je nejrozšířenější formát se ztrátovou kompresí, tím se záměrně vypustí informace, kterou lidské oko nevnímá. V případě tohoto formátu dochází ke ztrátě informace, tudíž je komprimovaný obraz v porovnání s originálem pozměněn. Pro účely ukládání biomedicínských dat je běžně využíván. Pro posouzení obrazu lékařem a klinické účely formát plní svou funkci. Pro pokročilejší analýzu obrazu formát již není vhodný, neboť dochází ke ztrátě informace, jak bylo zmíněno výše.
- Graphics Interchange Format je bezztrátový formát vhodný pro internetovou grafiku. Pro zobrazování fotografií nebo medicínských dat je nevhodný, protože obraz obsahuje pouze omezený počet barev.
- Formát TIFF již může obsahovat komprimovaná data jinými kodexy. Tento formát taktéž umožňuje bezztrátovou kompresi a ukládání barevných obrázků ve velkém rozlišení.
- Datový formát DICOM je využíván v medicíně. V tomto formátu jsou uchovány sekvence a obrazy v běžných datových formátech doplněné o textové informace včetně diagnostické modality a informací o pacientovi. Digital Imaging and Communication in Medicine slouží taktéž jako síťový protokol pro manipulaci, ukládání, tisk a přenos biomedicínských obrazových dat v systému PACS¹⁶. PACS představuje virtuální prostor pro ukládání těchto dat [1][8].

Tabulka 1: Přehled vlastností obrazových formátů [1]

Formát	Komprese	Barvy	Vhodnost pro biomedicínské obrazy
BMP	ne	model <i>RGB</i>	ne
GIF	bezeztrátová	paleta	ne
PNG	bezeztrátová	model <i>RGB</i>	ano
JPEG	ztrátová	model <i>Y C_B C_R</i>	podmíněně
TIFF	volitelná	volitelné	ano
DICOM	bezeztrátová	šedá škála	ano

⁹ PDF – Portable Document Format.

¹⁰ BMP – BitMaP.

¹¹ JPEG – The Joint Photographics Experts Group.

¹² PNG – The Portable Network Graphics.

¹³ GIF – Graphics Interchange Format.

¹⁴ TIFF – Tag Image File Format.

¹⁵ DICOM – Digital Imaging and Communication in Medicine.

¹⁶ PACS – Picture Archiving and Communication System.

2 Segmentace zájmových struktur

Vzhledem k různým typům obrazových dat, útvarům a cílům segmentace je nemožné použít jednu univerzální segmentační metodu [4]. Následující kapitola se bude zabývat prahováním, hranově a regionově orientovanou segmentací, pixelovou klasifikací, metodou Watershed a metodami umělé inteligence.


2.1 Prahování

Prahování je nejjednodušší metoda a většinou prvotní operace v procesu segmentace obrazu. Základem této metody je definování hodnoty neboli segmentačního prahu, který oddělí objekty od pozadí. Medicínský obraz je rozdělen na části s hodnotou pixelů stejnými/vyššími než práh a nižšími než práh. Pixely s nadprahovou hodnotou tvoří popředí, pixely s hodnotou nižší než práh vytváří pozadí. Výsledkem metody je binární obraz, kde hodnota 1 představuje popředí a hodnota 0 tvoří pozadí [4][12].

Podle počtu prahových hodnot, lze rozdělit prahování na globální, lokální a dynamické. Globální prahování je rychlé a jednoduché. Je určen pouze jeden segmentační práh. V tomto případě je segmentace oblasti zájmu pomocí jednoho prahu často velmi nepřesná. U lokálního prahování je např. obraz rozdělen do podoblastí a segmentační práh je určen pro každou oblast zvlášť. Dynamické prahování je založeno na analýze okolí pixelu [4].

2.1.1 Otsu metoda

Pro automatické určení prahu je využívána např. Otsu metoda, která určí hodnotu prahu z histogramu snímku. Metoda funguje na principu diskriminace dvou tříd. Segmentační práh má takovou hodnotu, která minimalizuje vážený rozptyl mezi třídami jasů popředí a pozadí [8][12].



Obrázek 7: Histogram snímku, princip Otsu metody, upraveno [8].

2.1.2 Rosenfeldova, Sezanova a Rameshova metoda

Tyto metody také využívají k určení prahové hodnoty histogram. **Rosenfeldova metoda** analyzuje konkávnost histogramu obrazu. Nejhlubší konkávní body jsou většinou považovány za segmentační práh. **Sezanova metoda** je metoda vrcholů a údolí. Dochází k analýze sloučeného histogramu funkce s vyhlazovacím jádrem. Prahová hodnota se nachází mezi prvním ukončením a druhým zahájením přechodu nulou. Práh v **Rameshově metodě** je získán funkční aproximací¹⁷ [13].

2.1.3 Procentuální prahování

Procentuální prahování vyplývá z procentuálního pokrytí obrazu jednotlivými objekty. Na obrázku 8 je znázorněna segmentace se segmentačním prahem 0,4. Tzn., že 40 % plochy obrazu tvoří objekty. 40 % obrazových bodů má barvu objektů a zbylých 60 % tvoří pozadí [8].



Obrázek 8: Segmentace prahováním, práh 0,4, vlevo originální obraz, vpravo výsledek segmentace [12].

2.2 Pixelová klasifikace

Metody pixelové klasifikace, které používají k určení segmentačního prahu statistiku histogramu, jsou považovány za zobecnění prahových technik. V jednorozměrných obrazech, tj. v obrazech ve stupních šedi, je pixelová klasifikace provedena na základě stupňů šedi a obrazová segmentace je dána jednorozměrnou prostorovou funkcí. V barevných obrazech jsou pixely charakterizovány souborem funkcí vyjádřeným pomocí vektorů ve vícerozměrném prostoru funkcí. V tomto případě probíhá segmentace pomocí shlukovací analýzy [4].


2.2.1 Riddlerova metoda

Metoda rozděluje pixely podle prahu, který je určen aritmetickými průměry tříd popředí a pozadí. Při každém opakování je určen nový práh [13].


¹⁷ Přiblížení, odhad.

2.2.2 Lloydova metoda a Kittlerova metoda

Tyto metody se snaží o minimální chybovost v určování segmentačního prahu. Předpokládají, že obraz je směs distribucí popředí a pozadí. **Lloydova metoda** uvažuje stejný rozptyl Gaussovy funkce a prostřednictvím opakovaného vyhledávání minimalizuje chybu nesprávné klasifikace. **Kittlerova metoda** se snaží najít takový segmentační práh, jehož hodnota odpovídá minimálnímu průniku mezi třídami [13][14].



Obrázek 9: Prahování sítnice Lloydovou metodou [14].




Obrázek 10: Prahování sítnice Kittlerovou metodou [14].

2.3 Hranově orientovaná segmentace

Hranově orientovaná segmentace je založená na detekci hran v obraze. Hrana je soubor pixelů ležících na pomezí dvou oblastí s rozdílnou intenzitou. Hrana může být charakterizována jako náhlá změna jasové intenzity. K detekci hran se používají gradientní operátory, např. Cannyho, Sobelův, Prewittové, Robertsův operátor. Pro výpočet gradientu je nutný výpočet parciálních derivací souřadnic každého pixelu. Výsledkem segmentace je hranová mapa. Nevýhodou hranové segmentace je velká citlivost na šum [4].

Na obrázku 11 je ukázán detail hrany obrazu a grafické znázornění první a druhé derivace. Je patrné, že první derivace je v oblasti s konstantním jasnem nulová a v místě hrany kladná. Druhá derivace je v místě hrany nulová. V místě, kde funkce dosahuje minima (tmavá strana hrany), je kladná, a kde dosahuje maxima (světlá strana hrany), je záporná [4][15].



Obrázek 11: Detail hrany při hranové segmentaci, zobrazení derivací [15].

2.3.1 Metody založené na první derivaci

Již výše bylo zmíněno, že se jedná o metody, kdy v místě hrany je derivace kladná a v místě s konstantním jasnem nulová. Pro obraz definován funkcí $f(x,y)$ je gradient ∇f s lokací (x,y) , charakterizován jako vektor:

$$\nabla f = \begin{bmatrix} \mathcal{F}_x \\ \mathcal{F}_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix}, \quad (2.1)$$

kde \mathcal{F}_x a \mathcal{F}_y jsou gradienty vypočítané ve směru osy x a osy y [4].

Hrana je určena hodnotou gradientu ∇f , tj. velikostí a směrem. Velikost gradientu udává maximální nárůst funkce $f(x, y)$ na jednotku vzdálenosti ve směru gradientu [4].

$$|\nabla f| = \sqrt{(\mathcal{F}_x)^2 + (\mathcal{F}_y)^2} \quad [4] \quad (2.2)$$

Směr gradientu je vyjádřen úhlem θ , úhel je měřený k ose x [4].

$$\theta = \tan^{-1} = \left(\frac{\mathcal{F}_y}{\mathcal{F}_x} \right) \quad [4] \quad (2.3)$$

Prewittové operátor

U tohoto operátoru se provádí konvoluce¹⁸ s osmi maskami navzájem pootočenými o 45 stupňů. Za výsledek se pokládá hodnota s nejvyšší absolutní hodnotou [1].

Sobelův operátor

Sobelův operátor se používá pro výpočet svislých a vodorovných hran. Vybírá se opět nejvyšší absolutní hodnota. Stejně jako operátor Prewittové, je Sobelův operátor citlivý na šum [1][16].

Robertsův operátor

Jedná se o jeden z nejjednodušších operátorů. Nejlépe detekuje hranu pod úhlem 45 stupňů a 135 stupňů. Využívá okolí dvou pixelů a je velmi citlivý na šum z důvodu malého okolí použitého pro aproximaci [16].

2.3.2 Metody založené na druhé derivaci

První derivace je při náhlé změně jasu kladná. Metody založené na druhé derivaci fungují tak, že v místě s největší intenzitou jsou rovny nule. Hrana se tedy nachází tam, kde je druhá derivace rovna nule. Pomocí druhé derivace je získána pouze informace o poloze hrany, velikost ani směr hrany druhou derivací určit nelze. Pro detekci hrany se buď používá dvojí výpočet první derivace, nebo hranový operátor počítající druhou derivaci [4][15].

Laplaceův operátor

Nejpoužívanější hranový operátor se nazývá Laplaceův. Nevýhodou tohoto operátoru je vysoká citlivost na šum. Je definován následujícím vztahem: [4][15]

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \quad [4]. \quad (2.4)$$


¹⁸ Konvoluce je matematická operace dvou funkcí. Obraz převedený do matice je násoben konvolučním jádrem. Konvoluční jádro je matice o určité velikosti, která závisí na zvoleném operátoru. Hodnoty v konvolučním jádře se buňka po buňce postupně posouvají a násobí maticí obrazu. Jednotlivé hodnoty se poté sečtou a uloží na příslušné místo zpracovávané matice [1].

Laplacián Gaussiánu

Laplacián Gaussiánu LoG^{19} je filtr tvaru Gaussovy křivky a používá se před samotnou aplikací Laplaceova operátoru. Použitím filtru dochází k redukci vysokofrekvenčního šumu a výsledky detekce hran jsou přesnější [16].

Cannyho operátor

Tomuto operátoru se také říká optimální detektor hran. Je charakteristický svou nízkou chybovostí, kdy nachází v obraze všechny podstatné hrany a falešně nedetekuje. Vzdálenost mezi detekovanou a skutečnou polohou hrany by měla být minimální. Každá hrana je detekována pouze jednou. Na základě těchto kritérií operátor vyhladí obraz, najde gradient obrazu pro zvýraznění určitých oblastí, potlačí oblasti lokálního minima a eliminuje nevýznamné hrany pomocí hystereze²⁰ [16].



Obrázek 12: Srovnání hranových operátorů, A: originální obraz; B: Cannyho; C: LoG; D: Robertsův; E: Prewittové; F: Sobelův, upraveno [19].

2.4 Regionově orientovaná segmentace


Hranově orientovaná segmentace se na zašuměné obrazy nehodí, protože špatně detekuje hrany objektů. V takovém případě je vhodnější použít regionově orientovanou segmentaci obrazu. Tato metoda je založená na homogenitě oblastí, které jsou definovány společnými parametry,

¹⁹ LoG – Laplacian of Gaussian.

²⁰ Hystereze se používá pro zbývající nepotlačené pixely. Využívá dvě prahové hodnoty, pokud je velikost gradientu menší než první prahová hodnota, je nastavena na nulu, je-li nad druhou prahovou hodnotou, tak vytváří hranu. Velikost gradientu v rozmezí prahového intervalu je nastavena na nulu v případě, kdy nesousedí s bodem, který byl za hranu označen již dříve [16].

např. tvarem, barvou, úrovní šedi atd. Tento druh segmentace lze provést metodou růstu oblastí, metodou dělení oblastí, metodou dělení a slučování oblastí [4].

Obrázek 13 vlevo zachycuje mamografický snímek, snímek vpravo je segmentován do tří regionů. Každý region je typický barvou označující určitou tkáň/oblast. Tmavě šedá zobrazuje pozadí, šedá indikuje měkkou tkáň a světle šedá oblast prsu.



Obrázek 13: Regionově orientovaná segmentace, vlevo originální obraz, vpravo výsledek segmentace [12].

2.4.1 Segmentace růstem oblastí

Jedná se o nejjednodušší techniku regionově orientované segmentace. Segmentace růstem oblastí se málokdy používá samostatně, většinou je součástí souboru operací. Slouží pro detekci malých a jednoduchých struktur, konkrétně lézí a nádorů. Cílem je extrahovat z obrazu region s podobnými vlastnostmi pixelů. Princip algoritmu spočívá v určení měřítka podobnosti p , kritéria zastavení a určení pixelů, tzv. semínek. Měřítka podobnosti zahrnuje pixely do regionu, většinou je rozhodnuto na základě hodnoty jasu. Kritérium zastavuje růst regionu. K získání semínek je nutná manuální interakce, což je hlavní nevýhodou této metody. Sousedící pixel každého semínka je zkontrolován algoritmem, pokud má podobné vlastnosti, je přidán do regionu [4][17]. Hodnoty parametrů se porovnávají dle následující nerovnosti:

$$|p_s - p_j| \leq T, \quad (2.5)$$

kde p_s je referenční parametr semínka, p_j představuje parametr porovnávaného pixelu a T je rozhodovací úroveň charakterizující maximální přípustnou hodnotu intenzity [18].

Region roste a jeho tvar se mění. Tento proces stále pokračuje, dokud nelze do regionu přidat žádný pixel. Po skončení algoritmu je pravděpodobné, že některé pixely zůstanou nepřirazené [4].

2.4.2 Segmentace dělením oblastí


Segmentace dělením oblastí je opačný proces od segmentace růstem oblastí. Tato metoda rozděluje velké nehomogenní oblasti na jednotné menší oblasti. Záleží na kritériu homogenity, které se volí na základě struktury obrazu. Velmi častou strukturou je quadtree neboli stromová struktura, kdy se obraz dělí na čtyři čtvrtinové podoblasti. V podoblastech je opět zkoumáno splnění kritéria homogenity, pokud není kritérium splněno, tak se podoblast dělí na další čtyři části. Proces dělení probíhá do té doby, dokud každá rozdělená část obrazu nesplňuje kritérium homogenity [4].

2.4.3 Segmentace dělením a slučováním oblastí

Nevýhodou segmentace dělením oblastí je, že finální segmentovaný obraz může obsahovat velký počet přilehlých oblastí, které jsou homogenní. Z tohoto důvodu byla vyvinuta metoda segmentace dělením a slučováním oblastí, jejíž princip spočívá v rozdělení obrazu, kontrolou, zda jsou přilehlé oblasti homogenní, a následným sloučením [4].

2.5 Metoda Watershed

Metoda Watershed je tzv. metoda hybridní. Hybridní metody obsahují vlastnosti již výše zmíněné a jejich jednoznačné zařazení není možné. Metoda Watershed vychází z geografického základu, obraz je chápán jako reliéf zaplavovaný vodou. Výška terénu je dána jasem. Jsou určena minima obrazu, reliéf se postupně zaplavuje a tam, kde hrozí slití vody ze dvou povodí, se vytvoří hráz. Po dosažení maxima v obraze metoda končí. Metoda je jednoduchá, rychlá a dochází ke kompletnímu rozdělení obrazu. Mezi její hlavní nevýhody patří nadměrná segmentace (obrázek 14), citlivost na šum, špatná detekce tenkých struktur, špatná detekce oblastí s nízkým kontrastem a výpočetní náročnost [12][18].




Obrázek 14: Metoda Watershed, vlevo originální obraz, vpravo výsledek segmentace [12].


2.6 Metody umělé inteligence

Umělá inteligence jsou systémy nebo stroje napodobující lidské schopnosti, vnímající prostředí a maximalizující své šance na úspěch. Umělé sítě výkonných prvků napodobují funkci živých neuronů, proto se nazývají neuronové sítě. Signál vstupuje do těla neuronu skrz dendrity. Tělo buňky sčítá signály okolních neuronů a dochází zde k vybuzení neuronu. Axony přenášejí signál k synapsím, které ho zeslabují/zesilují a předávají dalším neuronům. Síť je tvořena vstupní, výstupní a alespoň jednou vnitřní vrstvou. Pokud je vrstev více, jsou navzájem mezi sebou propojeny [20][21][22].

V předešlých úlohách veškeré provedení akcí záviselo na naprogramovaném algoritmu. V neuronových sítích způsob transformace vstupních dat na data výstupní, určuje učení. Učení je založeno na množině vzorků, neboli trénovací množině, popisujících danou problematiku. Na trénovací množině se síť proškolí a poté je schopna aplikovat znalosti na data, se kterými nikdy předtím nepracovala [20].



Obrázek 15: Model neuronu, upraveno [20].



Obrázek 16: Propojení mezi vrstvami v neuronové síti, upraveno [22].

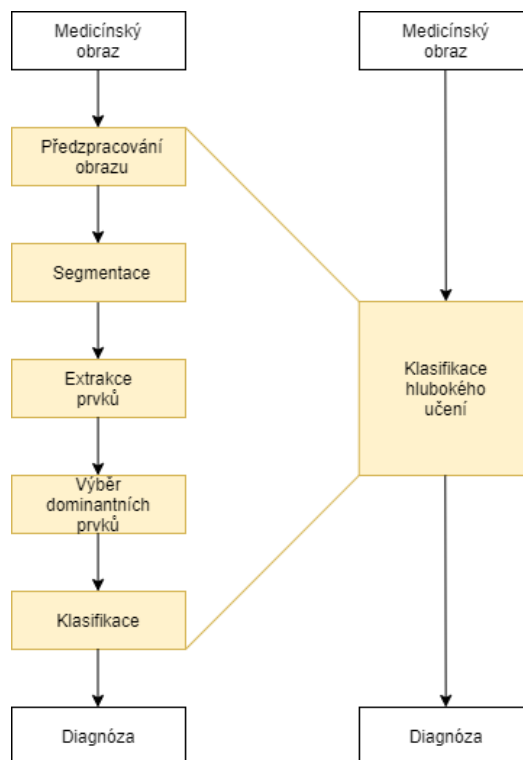
Pokud má neuronová síť mezi vstupní a výstupní vrstvou neuronů více skrytých vrstev, např. až 100, nazývá se hluboká neuronová síť. V každé vrstvě se provádí jiná matematická operace a tím může síť zpracovávat složitější data [21].

Neuronové sítě hrají důležitou roli v lékařském zobrazování, analýze lékařského obrazu a počítačové diagnostice. Některé objekty v obraze, léze a orgány, nemusí být snadno charakterizovatelné matematicky, proto se využívá neuronových sítí. Sítě jsou schopny tkáň klasifikovat, např. zda se jedná o maligní/benigní nádor. Přístupy strojového a hluboké učení jsou využívány při segmentaci obrazů [12][22].

2.6.1 Strojové a hluboké učení

Typickou aplikací strojového učení založenou na segmentaci oblasti zájmu je určení např. zdravé nebo patologické tkáně. Návrh této aplikace zahrnuje předzpracování obrazu, kdy dochází např. k odstranění šumu z obrazu a zvýšení kontrastu. Poté je obraz segmentován některou ze segmentačních technik. Po segmentaci jsou určité prvky extrahovány na základě barevné informace, textury, kontrastu a velikosti oblasti zájmu. Z těchto prvků jsou určeny dominantní prvky analýzou komponent nebo statistickou analýzou. Vybrané prvky jsou použity jako vstup do klasifikátoru strojového učení, který pracuje s vybranými prvky a označením tříd. Jsou určeny hranice, které definují každou třídu. Proškolený klasifikátor je dále aplikován na neznáma data [22].

Segmentace hlubokým učením může zpracovávat obraz bez nutnosti předzpracování obrazu, segmentace a extrakce funkcí, ale vyžaduje zmenšení velikosti obrazu kvůli omezení vstupních hodnot. Hluboké učení v porovnání se strojovým učení má vyšší přesnost klasifikace. Již bylo zmíněno výše, že se hluboká neuronová síť skládá z více vrstev. Každá vrstva transformuje vstupní data z předchozí vrstvy na vyšší úroveň prezentace. To umožňuje modelu síť se učit místní a vzájemné vztahy v hierarchické struktuře. Nejvyšší vrstvy poté detekují objekty prostřednictvím kombinací zjištěných informací z nižších vrstev [22].




Obrázek 17: Rozdíl mezi strojovým a hlubokým učení při segmentaci, upraveno [22].

Nejpoužívanějším typem neuronových sítí jsou konvoluční neuronové sítě. Tento typ sítě má trojrozměrné uspořádání neuronů, které jsou spojeny jen s malou oblastí předchozí vrstvy. Síť obsahuje konvoluční vrstvy, které zajišťují předzpracování obrazu a automaticky extrahují užitečné informace z obrazu pomocí konvoluce s naučenými filtry. S těmito informacemi poté pracuje klasifikátor [22].

2.6.2 Sémantická segmentace

Sémantická segmentace patří do metod hlubokého učení a rozděluje obraz na základě vizuálně podobných oblastí. Každý pixel je zařazen do příslušné sekce na základě sémantiky. Sekce se stejnými vlastnostmi spadají do jedné třídy. Obraz je dělen do několika tříd [22][23].



Obrázek 18: Sémantická segmentace, upraveno [23].

3 Základní principy registrace obrazu


V následující kapitole jsou uvedeny základní informace o registraci obrazu, postup registrace, problematika registrace a klasifikace registrace.

Registrace obrazu je proces založený na nalezení vhodné transformace tak, aby se souřadnicový systém jednoho obrazu shodoval se souřadnicovým systémem druhého obrazu. Obrazy vstupující do registrace se nazývají referenční R a plovoucí neboli deformovatelný T . Referenční obraz je ponechán beze změn. Plovoucí obraz je zarovnán s referenčním snímkem, převzorkován, transformován, zaregistrován [24][28]. Aby došlo k registraci obrazů, je hledána transformace $\varphi: R^2 \rightarrow R^2$. Referenční obraz R a transformovaný plovoucí T_φ jsou si podobné, pokud:

$$T_\varphi(x) = T \circ \varphi(x) = T(\varphi(x)) \quad [28]. \quad (3.1)$$

3.1 Postup registrace obrazu

Před procesem registrace je často nutné určit podobnostní kritéria jednotlivých obrazů, na základě kterých je určen typ transformace. Ve většině prostudovaných zdrojů převládá následující postup se čtyřmi kroky. Společně tyto čtyři části tvoří klasifikace podle devíti kritérií uvedených níže.



Obrázek 19: Jednotlivé kroky registrace [27].

1. Detekce funkcí (příznaků/vlastností) – ručně/automaticky jsou detekovány význačné objekty (hrany, rohy, regiony, atd). Význačné objekty by měly být snadno zjistitelné a často se v obraze opakují. Jelikož medicínské snímky neobsahují v porovnání s ostatními obrazy tolik objektů, při jejich registraci se využívají metody založené na ploše, které první krok registrace vynechávají a zaměřují se na zjišťování společných prvků.
2. Shoda funkcí (příznaků/vlastností) – zjištění prvků, které má referenční obraz společné s obrazem plovoucím. Pro tento účel se používají míry podobnosti a deskriptory²¹ funkcí. Důležité je, aby snímky měly dostatečný počet společných prvků. Detekovanými prvky mohou být hodnoty intenzity, prostorové rozdělení prvků nebo symbolický popis funkce.
3. Odhad modelu transformace – určení typu a parametrů mapovací funkce. Následuje transformace, aby si obrazy byly co nejvíce podobné.
4. Převzorkování a geometrická transformace – obraz je převzorkován a pomocí mapovací funkce transformován. Vzorkovací frekvence závisí na interpolaci a výpočetní náročnosti [24].

²¹ Popisy vizuálních vlastností.

3.2 Interpolace

Obraz je tvořen pixely, jejichž jasová intenzita je definována na pixelové mřížce. Pokud je plovoucí obraz transformován, dochází ke změně jeho souřadného systému. Tzn., že pixely plovoucího obrazu změní svou lokaci a mohou ležet mimo mřížku. Proto je nutné provést interpolaci, která navrhne alespoň přibližnou hodnotu pixelu [54].

Mezi základní typy interpolací je řazena metoda nejbližšího souseda, lineární, bilineární nebo bikubická. Interpolace nejbližšího souseda je nejjednodušší a výpočetně nenáročná. Je to aproximační metoda, kdy pixel ležící mimo mřížku přebírá hodnotu intenzity nejbližšího bodu původního obrazu. Bilineární interpolace je dvojitá lineární interpolace. Hodnota pixelu je vypočtena jako vážený průměr hodnot čtyř nejbližších bodů. Tyto interpolace jsou výpočetně náročnější, ale přesnější. Interpolace bikubická je obdoba bilineární, ale je do výběru zařazeno okolí 16 okolních bodů [54].

3.3 Problematika registrace obrazu

Hledání vhodné transformace je složitá a důležitá operace. Problém registrace snímků nastává, pokud snímky zobrazují téměř stejný objekt, ale tvar objektu, snímací zařízení či doba pořízení snímku se u obou snímků liší. Příkladem je registrace snímků pořízených před a po operaci pacienta, nebo registrace řezů histologického nálezu, kdy je cílem zachovat skutečné rozdíly mezi snímky, ale odstranit artefakty způsobené např. pohybem [28].

Pro matematické řešení problému jsou pro každou transformaci použity metriky podobnosti [28].

3.3.1 Metriky podobnosti

Metriky podobnosti neboli podobnostní míry definují, jak moc je referenční a transformovaný plovoucí obraz prostorově podobný. U metrik se lze setkat s dvěma termíny, s mírami podobnosti (např. vzájemná informace) a mírami vzdálenosti (např. střední kvadratická chyba). Míra podobnosti určuje podobnost mezi obrazy, je cílem ji maximalizovat. Míra vzdálenosti určuje odlišnost obrazů, cílem je hodnoty minimalizovat [33].

Metriky jsou důležitou částí optimální registrace. Optimální registrace je dosaženo v globálním maximu nebo v globálním minimu nákladové funkce neboli metriky. V následujících odstavcích jsou uvedeny základní podobnostní míry založené na intenzitě, korelaci a vzájemné informaci [28].

Metoda nejmenších čtverců neboli střední kvadratická chyba

Pro monomodální obrazy nebo obrazy, kde se předpokládá, že anatomické struktury mají stejné intenzity, je vhodná metrika součtu rozdílů čtverců. Tato metrika je závislá na intenzitě, tudíž jsou pro multimodální obrazy upřednostňovány jiné metriky podobnosti. Optimální registrace proběhne v minimu nákladové funkce [33].

U multimodálních obrazů jsou předpokládány rozdílné hodnoty intenzit jednotlivých snímků. V takovém případě je použita např. vzájemná informace. Je zavedena další funkce $g: R \rightarrow R$ a porovnáván referenční obraz R s obrazem $g \circ T\varphi(x) = g(T(\varphi(x)))$. Obecný zápis míry vzdálenosti D je následující:

$$D(R, g \circ T \circ \varphi) = \min [28]. \quad (3.2)$$

Vzájemná informace

Vzájemná informace je odvozená z informační teorie a představuje míru závislosti proměnných X, Y , tedy množství informací, které obsahuje jeden obraz z druhého. Pro výpočet vzájemné informace mezi obrazy R a T_φ , se používají náhodné proměnné X, Y a jejich hodnoty intenzity (R_k, T_k) . Tato dvojice intenzit existuje u každého pixelu. Čím více jsou proměnné X, Y na sobě závislé, tím je vzájemná informace větší [33].

Korelační koeficient

Křížová korelace je vhodná pro srovnání snímků stejného objektu, např. pro posouzení vývoje nemoci. Metoda spočívá ve výpočtu korelačního koeficientu. Korelační koeficient je vypočítán z okolí pixelu k z obrazu R a ze stejného okolí v obrazu T_φ . Tento algoritmus prochází pixely a jejich okolí celého obrazu. Po nalezení nejvyššího korelačního koeficientu, je provedena transformace obrazu. Nejvyšší korelační koeficient odpovídá nejvyšší shodě intenzit obou obrazů v daném místě. Metoda je odolná proti šumu, ale časově výpočetně náročná [28][33].

3.4 Klasifikace registrace obrazu

Registrace obrazu může být dělena na základě různých kritérií. Následuje jejich stručný přehled.

3.4.1 Registrace podle její aplikace

Pokud je registrace klasifikována podle aplikace, dělí se na čtyři skupiny. Ve všech čtyřech případech se jedná o snímání stále stejné scény. První skupinu tvoří obrazy snímání z různých pohledů. Druhá skupina snímá obrazy v různých časech. V medicíně se využívá např. k pozorování růstu nádorů. Třetí skupina aplikace snímá obrazy různými typy senzorů, kdy jsou zaznamenány anatomické struktury těla i metabolické procesy. Poslední skupina je srovnání obrazu pacienta s anatomickými atlasy [38].

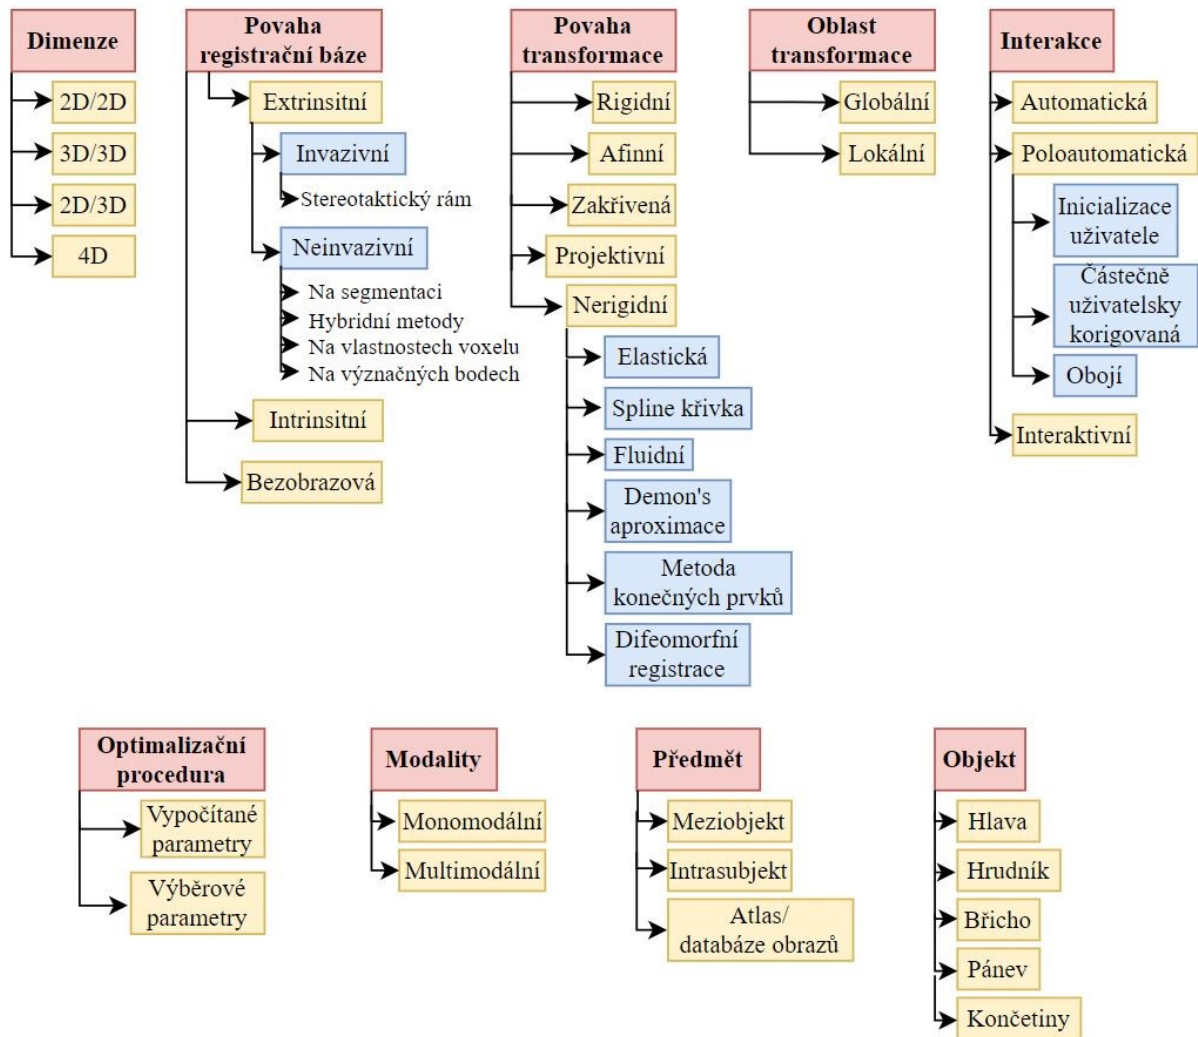
3.4.2 Registrace podle počtu parametrů

J. Modersitzki [28] rozdělil registrační metody do dvou skupin založených na počtu parametrů, pomocí kterých následně registrace obrazu probíhá. Metody jsou děleny na parametrické a neparametrické. Princip parametrické registrace spočívá v hledání optimálních parametrů k provedení transformace obrazu. Všechny techniky pracují s minimalizací určité míry vzdálenosti založené na vlastnostech obrazu nebo jeho intenzitě. Vlastnosti obrazu jsou dány uživatelem (např. význačné body) nebo určeny automaticky pomocí intenzity obrazu (např. hlavní osy, těžiště). U neparametrických metod registrace vychází z fyzikálních interpretací, probíhá na základě minimalizace míry vzdálenosti a regularizace [28].

3.4.3 Registrace podle devíti kritérií

Van den Elsen a kolektiv [37] navrhl klasifikaci registrace do devíti kritérií, jak lze vidět na obrázku 20. Toto dělení je běžně využíváno k registraci medicínských obrazů [38].

S využitím zdrojů [25][26][27][37][38] lze klasifikaci registrace rozdělit následovně:



Obrázek 20: Metody registrace, zdroj vlastní.

Počet dimenzí

Kritérium se zabývá počtem dimenzí registrovaných dat. Registrace 2D/2D znamená zarovnání 2D snímku s 2D snímkem, registrace 3D/3D zarovnání trojrozměrného snímku s trojrozměrným. Obecně platí, že registrace 3D/3D je komplexnější než registrace 2D/2D. Komplexní je registrace 2D/3D, kdy je 2D snímek zaregistrován do prostorových dat. Registrace časových snímků je také označována jako modalita 4D. Registrace 3D snímků v různých časových intervalech slouží např. k monitorování vývoje nemoci, reakci na léčbu, zjištění prokrvení tkání a metabolických procesů [34].

Povaha registrační báze

Metody registrace obrazu jsou děleny podle toho, zda jsou do obrazu přidány umělé objekty, nebo zda je registrace založená pouze na obrazových informacích pacienta. Při extrinsitní (vnější)

metodě jsou k pacientovi připojeny umělé objekty (např. stereotaktický rám), které představují jakési tvrdé význačné body sloužící k detekci daných struktur v obraze. Význačné body musí být dobře viditelné a měly by být zjistitelné ve všech modalitách. Hlavní nevýhodou je, že metody jsou mnohdy invazivní a pro pacienta bolestivé. Jsou však výpočetně efektivní, mohou být automatizovány a nevyžadují složité optimalizační algoritmy, takže parametry transformace jsou jednoduše vypočitatelné. Při intrinsitní (vnitřní) metodě jsou ze samotných snímků odvozeny měkké význačné body, kdy jsou k jejich určení nutné odborné znalosti, nebo nástroje pro ruční/automatickou detekci. Většinou jsou detekovány jednotlivé body, křivky a důležité povrchy, které lze porovnat v druhém obraze. Tento druh registrace může být také založen na výsledcích segmentace, kdy jsou z obou obrazů segmentovány struktury určené k registraci, nebo je z jednoho obrazu segmentována struktura, která je elastickou deformací zarovnána s referenčním obrazem. Dalším typem registrační báze je voxelová, která využívá pouze stupně šedi. Nevyžaduje předchozí redukci dat uživatelem ani segmentací. Hybridní algoritmy využívají kombinací intenzity a geometrických prvků [25][34].

Povaha transformace

Transformace je důležitým krokem registrace. Obecně je transformace změna prostorových souřadnic obrazu $P(x)$ do souřadnic transformovaného obrazu $P'(x)$ tedy:

$$P'(x) = \varphi(P(x)) \quad [35]. \quad (3.3)$$

Pokud je transformace reverzibilní, je možné obnovit originální obraz.

$$P(x) = \varphi^{-1}(P'(x)) \quad [35]. \quad (3.4)$$

Rovnice rigidní transformace je dána předpisem:

$$\varphi(x) = Ax + b, \quad (3.5)$$

kde A představuje rotační matici o velikosti $n \times n$, x je bod v obraze značící jeho prostorové souřadnice (x, y, z) , b značí posuvný sloupcový vektor. Transformace je prováděna rotací, translací nebo změnou měřítka. Vektor $[x \ y \ z]^T$ představuje souřadnice pixelu plovoucího obrazu a vektor $[x' \ y' \ z']^T$ charakterizuje souřadnice pixelu obrazu transformovaného, které by měly být velmi podobné obrazu referenčnímu [33][34][35][36].

2D translace:

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & b_x \\ 0 & 1 & b_y \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (3.6)$$

3D translace:

$$\begin{bmatrix} x' \\ y' \\ z' \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & b_x \\ 0 & 1 & 0 & b_y \\ 0 & 0 & 1 & b_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix} \quad (3.7)$$

Při translaci nedochází k rotaci obrazu, tudíž matice obsahuje pouze posuvný vektor b [35][36].

2D rotace:

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} \cos(\theta) & -\sin(\theta) & 0 \\ \sin(\theta) & \cos(\theta) & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (3.8)$$

3D rotace:

$$\begin{bmatrix} x' \\ y' \\ z' \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos(\theta_x) & -\sin(\theta_x) & 0 \\ 0 & \sin(\theta_x) & \cos(\theta_x) & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos(\theta_y) & 0 & \sin(\theta_y) & 0 \\ 0 & 1 & 0 & 0 \\ -\sin(\theta_y) & 0 & \cos(\theta_y) & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos(\theta_z) & -\sin(\theta_z) & 0 & 0 \\ \sin(\theta_z) & \cos(\theta_z) & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix} \quad (3.9)$$

Rotace je charakteristická úhlem natočení θ . Pro osy x, y, z jsou definovány úhly $\theta_x, \theta_y, \theta_z$ [35][36]. Při zápisu těchto znamének u goniometrických funkcí probíhá rotace proti směru hodinových ručiček.

2D změna měřítka:

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} s_x & 0 & 0 \\ 0 & s_y & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (3.10)$$

3D změna měřítka:

$$\begin{bmatrix} x' \\ y' \\ z' \\ 1 \end{bmatrix} = \begin{bmatrix} s_x & 0 & 0 & 0 \\ 0 & s_y & 0 & 0 \\ 0 & 0 & s_z & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix} \quad (3.11)$$

Změna měřítka představuje zmenšení či zvětšení obrazu a je definována parametrem s [35][36].

Afinní transformace je transformace mapující rovnoběžky z plovoucího obrazu na rovnoběžky z referenčního obrazu. Projektivní transformace mapuje čáry na čáry. Pokud jsou mapovány čáry na křivky, jedná se o transformaci zakřivenou. Některé druhy transformace lze vidět na obrázku 21 [25].

Nelineárním transformacím, nerigidním, se taktéž říká deformovatelné a lze je rozdělit na parametrické a neparametrické [33]. Parametrické transformace jsou vyjádřeny bázovou funkcí a pomocí parametrů:

$$\varphi(x) = x + \sum_{i=1}^n W_{i1} f_i(x) e_1 + W_{i2} f_i(x) e_2 + \dots + W_{in} f_i(x) e_n, \quad (3.12)$$

kde $f_i(x)$ je bázová funkce, např. Fourierova nebo B-spline funkce, parametr e_n , je jednotkový vektor čtyř hlavních směrů a W_{in} jsou koeficienty bázové funkce [28][33]. V neparametrických metodách registrace je každému bodu v obraze definován vektor $v(x)$ a transformace φ má předpis:

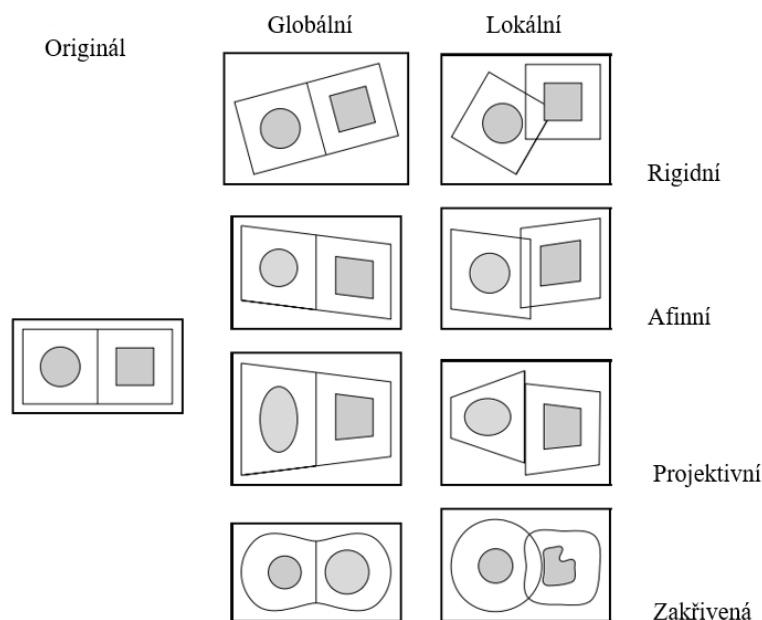
$$\varphi(x) = x + v(x) \quad [33]. \quad (3.13)$$

Registrace probíhá na základě regularizované minimalizace míry vzdálenosti. Regulátor se používá k výběru nejvhodnějšího řešení registrace [28].

Nerigidní transformace spline křivkou spočívá ve značení zdrojových a cílových bodů. Funkce spline počítá vztah mezi těmito body. Fluidní transformace je vhodná pro registraci tekutin. Metoda konečných prvků je rozšířená na modelování mozkových tkání, myokardu a kostí [25].

Oblast transformace

Transformace globální provádí transformaci s celým obrazem, zatímco transformace lokální pouze s jeho částí [25]. Ukázka transformací je na obrázku 21.



Obrázek 21: Druhy transformací, upraveno [26].

Interakce

Interakcí se rozumí velikost zásahu uživatele do procesu registrace. Automatická registrace vyžaduje pouze zadání algoritmu s obrazovými daty. Při interaktivní registraci uživatel provádí registraci sám za podpory softwaru poskytujícího vizuální a numerickou zpětnou vazbu. Pokud uživatel

musí vyvolat algoritmus, např. segmentací dat, nebo potvrdit či odmítnout navrhovanou metodu registrace, jedná se registraci poloautomatickou [34].

Optimalizace

Optimalizace se provádí za účelem zisku optimálních parametrů transformace. Platí, že čím více je registrace nerigidní, tím je nutný větší počet parametrů. Parametry lze najít dvěma způsoby, buď jsou vypočítány přímo z obrazové informace, nebo na základě optimalizačního kritéria metriky podobnosti [25][34].

Modality

Při monomodální aplikaci jsou registrované obrazy stejné modality, zatímco u multimodální registrace jsou obrazy různých modalit, např. CT snímek a snímek z MRI. CT, MRI, RTG a US zobrazují anatomickou strukturu, tedy pevné a měkké tkáně těla. Zatímco SPECT a PET lépe snímají fyziologické informace pacienta. Spojením modalit vznikne obraz s anatomickou i fyziologickou informací ve vysokém rozlišení a poskytne lékaři detailní informace o pacientovi [25][34].

Předmět

Pokud je provedena registrace snímků jednoho pacienta, je tzv. intrasubjektivní. Intersubjektivní registrace obsahuje obrazy různých pacientů. Posledním druhem této skupiny jsou registrace pomocí atlasů, kdy jeden obraz tvoří snímek pacienta, a druhý je získán z obrazové databáze [34].

Objekt

Objekt představuje část těla, která je snímána a registrována [34].

4 Rešerše aplikací registrace obrazu

Tato kapitola je věnována registraci multimodálních dat z oblasti mozkové tkáně. Multimodální registrace je proces, kdy dochází k překrytí snímků z různých zobrazovacích technik, např. CT a MRI, nebo MRI (T1²², T2²³, PD²⁴ obraz). Tímto způsobem dochází k získu úplnějších informací o pacientovi, neboť každá modalita zobrazuje jiný typ tkáně. V medicíně je tento typ registrace hojně rozšířený. Velké množství přístupů k registraci je založeno na vzájemné informaci MI, kterou je velmi těžké optimalizovat pro velký počet složitých vztahů mezi proměnnými a intenzitami pixelů [25][31].

Zdroj [32] dělí automatickou multimodální registraci na tři skupiny, registraci na úrovni pixelů, registraci na úrovni funkcí a registraci založenou na hlubokém učení.

Registrace na úrovni pixelů zkoumá vztah mezi pixely jednotlivých obrazů. Využívá celou pixelovou informaci, aby vytvořila vhodnou transformaci obrazu a určila míru podobnosti obrazů. Do této skupiny registrací je zahrnuta metoda vzájemné korelace, metoda vzájemné informace a metoda vřetenového těžiště. Jelikož metody registrují na základě informace celého pixelu, jsou citlivé na hluk a mají nízkou účinnost [32].

Registrace na úrovni funkcí pracuje s vlastnostmi obrazu. Nejprve jsou z obrazu vybrány důležité podobné funkce, které se nachází v obou obrazech. Cílovou funkcí mohou být hrany, textury nebo zakřivení. Poté je nalezen parametr funkce sloužící k maximalizaci podobnosti. Vzhledem k tomu, že jsou při registraci používány pouze pixely funkce, je proces registrace mnohem účinnější [32].

Registrace založená na hlubokém učení je novým typem registrace a dále jsou zkoumány její nedostatky jako omezená použitelnost na určitou modalitu, omezená vstupní data a vyhodnocení registrace [32].

4.1 Registrace na základě segmentace obrazu a symetrické soběpodobnosti

Cílem této studie bylo navržení postupu pro multimodální registraci lékařského obrazu založené na segmentaci obrazu a symetrické soběpodobnosti. Studie k registraci využila modální nezávislé soběpodobné informace a informace o modální konzistenci. Konkrétně byly navrženy 2 symetrické operátory, které sloužily k vymezení segmentace a přeměňovaly každý medicínský snímek do sjednoceného módu. Studie si kladla za cíl minimalizovat chyby registrace pomocí rotace a posunutí plovoucího snímku, a tak zvýšit její přesnost. Metoda využila k segmentaci MRI snímků mozku fuzzy C-means (FCM²⁵) algoritmus a použila informaci o podobnosti snímků [32].

Navrhovaná metoda se skládala z několika kroků, BCFCM²⁶, MSR²⁷, binarizace a omezení symetrie. Algoritmus BCFCM je algoritmus pro segmentaci lékařského obrazu a korekci zkresleného pole založený na FCM, což je shlukovací algoritmus. Jeho hlavní myšlenkou je maximální podobnost mezi objekty rozdělenými do stejného klastru a podobnost mezi různými klastry je minimální. Algoritmus se tedy používá k segmentaci původního plovoucího obrazu a původního referenčního obrazu. Metoda

²² T1 obraz – obraz pořízený v čase, kdy dojde k obnovení podélného vektoru magnetizace na 63 %.

²³ T2 obraz – obraz pořízený v čase, za který dojde k poklesu příčného vektoru magnetizace na 37 %.

²⁴ PD obraz – proton denzitní obraz.

²⁵ FCM – Fuzzy C-means, fuzzy C-means shlukování.

²⁶ BCFCM – Bias Corrected Fuzzy C-means, korekce zkreslení fuzzy C-means shlukováním.

²⁷ MSR – Mirror Symmetry via Registration, metoda zrcadlové symetrie.

zrcadlové symetrie MSR je charakteristická pro detekci osy symetrie původního referenčního obrazu a původního plovoucího obrazu a extrahování rovnice osy symetrie [32].

Hodnoty pixelů jednotlivých obrazů byly odlišné, proto byl referenční a původní obraz sjednocen do stejné modality tak, aby hodnoty pixelů odpovídajících umístění, byly co nejkonzistentnější. Registrace nakonec probíhala pomocí metriky SSD²⁸. Dále se obrázky segmentovaly binarizací, což je výhodné pro odstranění nízkofrekvenčního šumu v cílovém obrazu. Následovalo přibližné omezení symetrie, výsledné obrazy se zaznamenaly jako referenční obraz a plovoucí obraz pro registraci. Inicializovali se parametry registrace matice pevné transformace [32].

Z porovnávacích experimentů vyplynul lepší výkon registrační procedury navrhované metody v porovnání s ostatními metodami. Ve srovnání s RSSD²⁹ má navrhovaná metoda velké zlepšení v rotaci i translaci. Zejména u translačních experimentů je navrhovaná chyba metody menší než 1 mm, zatímco chyby ostatních metod jsou větší než 1 mm [32].

Experimentální výsledky ukázaly, že navrhovaná metoda může účinně snížit chybovost mozkové MRI multimodální registrace medicínského obrazu s rotačními a translačními transformacemi. Byla použita metoda BCFCM k segmentaci obrazu a extrahování cílových oblastí, metoda MSR, na jejímž základu byla provedena binarizace. Byla brána v úvahu symetrie levého a pravého mozku, navrženy dva druhy operátorů omezení podobnosti, které byly prospěšné pro odstranění dalšího šumu. Ve srovnání se současnými registračními schématy pro zpracování modálních obrazů se soběpodobnými deskriptory (jako jsou SSC³⁰, RSSD a miLBP³¹) měla navrhovaná metoda zjevné výhody v přesnosti registrace [32].

4.2 Metoda registrace obrazu maximalizací vzájemných informací

Jedná se o hojně využívanou metodu registrace již od roku 1995. Základním principem je maximalizace vzájemné informace MI. Registrace odpovídá maximalizaci vzájemné informace MI, pokud množství informací, které navzájem obrazy obsahují, je maximální [28].

Ve zdroji [29] navrhuje Yamamura a spol. novou metodu, jejímž úkolem je zvýšit přesnost registrace a zkrátit dobu zpracování obrazu. Automatická metoda byla testována na snímcích z CT a MRI a vzájemnou informaci zde byla intenzita. K multimodální registraci bylo zapotřebí předzpracování obrazu, kdy byl odstraněn šum a normalizována velikost obrazu. V dalším kroku byl pomocí těžiště detekován počáteční bod. Při výpočtu vzájemné informace se intenzity odpovídajících bodů dvou obrazů použily pro vytvoření 2D histogramu. Po zjištění vzájemné informace byla intenzita pixelu lineárně převedena z 0 na 255. Velikost pohybu cílového obrazu byla určena pomocí optimalizace, která k tomu využívá Powellovu metodu, jejíž index je vzájemná informace [29].

Plovoucí obraz byl transformován. Pro zkrácení výpočetního času byla trojrozměrná data převedena na dvojrozměrná. Registrace byla provedena vzájemnou výměnou informací a parametry transformační matice upraveny optimalizací. Výzkum dospěl k závěru, že navrhovaná metoda byla o ¾ času rychlejší než srovnávaná metoda [29].

²⁸ SSD – Sum of Squared Differences, součet rozdílů čtverců, střední kvadratická chyba.

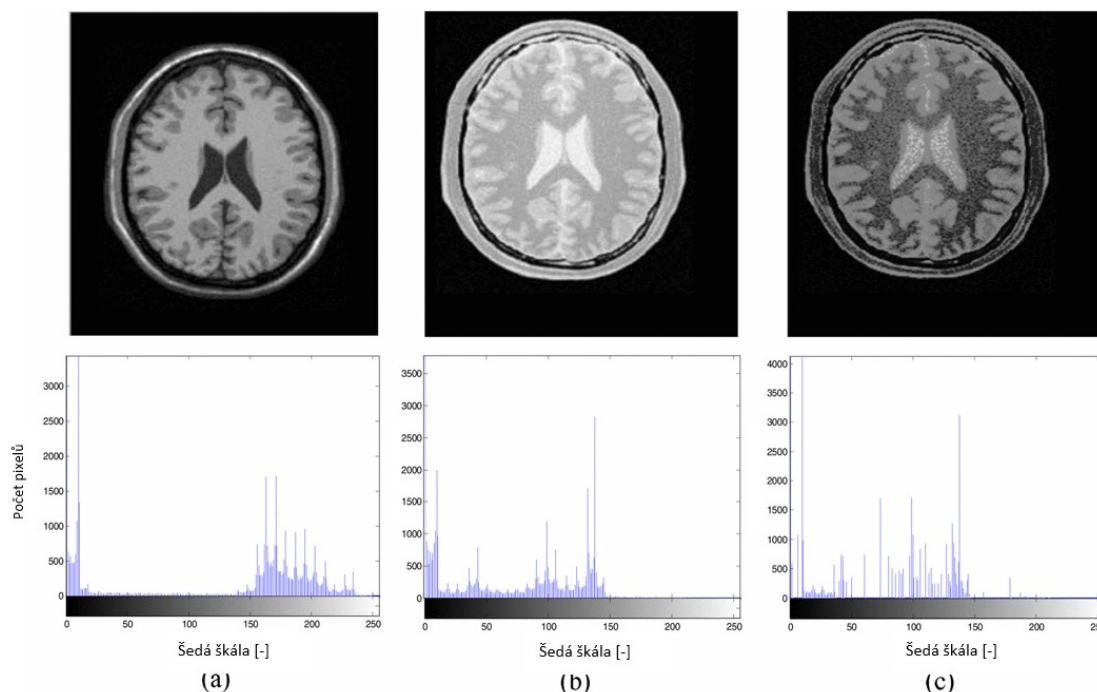
²⁹ RSSD – Robust Self-similarity Descriptor, robustní deskriptor soběpodobnosti.

³⁰ SSC – Self-Similarity Context, kontext soběpodobnosti.

³¹ miLBP – modality-independent Local Binary Pattern, modálně nezávislý binární deskriptor.

4.3 Registrace multimodálních mozkových obrazů na základě optického toku

Studie se zabývala registrací multimodálních obrazů na základě optického toku a zrychlené robustní funkce SURF³². Následně byla nová registrační metoda srovnána s metodami SURF, metodou založenou na démonech a na vzájemné informaci. Metoda vyžaduje pouze malé transformace. Tradiční metody registrace založené na optickém toku nejsou pro multimodální obrazy vhodné, protože dochází ke ztrátě informací z obrazu vlivem přílišného vyhlazení. Cílem bylo navržení rychlé výpočetně nenáročné metody, která by vyřešila problém s rozmazáním obrazu a ztrátou důležitých detailů obrazu [30].




Obrázek 22: Histogramová specifikace: (a) referenční obraz a jeho histogram; (b) plovoucí obraz a jeho histogram; (c) výsledný obraz s histogramem [30].

Nejprve byla provedena histogramová specifikace, která sloužila k transformaci modality plovoucího obrazu tak, aby byla stejná s referenčním. Upravila intenzity jednotlivých pixelů, aby zvýšila celkový kontrast obrazu a rozložení intenzity jasu bylo po celé škále dat stejné [30].

Poté pomocí metody SURF byly extrahovány hlavní body obrazu, tím byl získán předběžně registrovaný obraz. K získání přesnějších výsledků byl použit optický tok. K získání významných výsledků je nutné určení počtu interací a váhy vyhlazovacího členu. Metoda dospěla ke srovnatelným výsledkům jako ostatní metody [30].

³² SURF – Speeded up Robust Features.



Obrázek 23: Výsledky studie: (a) plovoucí obraz; (b) referenční obraz; (c) metoda založená na optickém toku a SURF; (d) metoda založená na démonech; (e) metoda SURF; (f) metoda MI [30].

4.4 Rigidní registrace obrazu založená na očekávané hodnotě maximalizace

Ve zdroji [31] byla srovnána metoda vzájemné informace MI a metoda očekávané hodnoty maximalizace EM³³. Metoda registrace očekávanou hodnotou maximalizace je typická nízkými výpočetními náklady s lineární optimalizací a intuitivním vztahem mezi proměnnými, který metodě MI chybí. Algoritmus EM poskytuje podobnost obrazů na základě intenzity. Metodika registrace EM byla provedena v pyramidové stupnici k dosažení větších rozsahů transformace a ke zkrácení výpočetního času.

Bylo provedeno syntetické srovnání mezi registračním algoritmem MI a metodou EM pomocí obrazů MRI v čase T1. Byly nastaveny následující parametry:

- úhly natočení v rozsahu 5 °; 10 °; 15 °; 20 ° a 25 °,
- posunutí 5; 10; 15 a 20 mm pro každou osu,
- intenzita odpovídala nelineární gama transformaci,
- měřítko s rozsahem 1; 2; 4; 0,5 a 0,25 [31].

Bylo vygenerováno 400 snímků s náhodnou transformací, aby se otestovala každá metoda registrace. Po vyhotovení registračního procesu oběma metodami, byl vypočten index DICE³⁴ a výpočetní čas každé metody. DICE index obsahoval bílou hmotu, šedou hmotu, mozkomíšní mok a lebku. Nakonec byla provedena mezní analýza (tj. transformace intenzity gama, úhel rotace v rigidní transformaci a hladina šumu) s ohledem na index DICE a výpočetní čas. Během syntetického

³³ EM – Expectation Maximization, očekávaná hodnota maximalizace.

³⁴ DICE – Koeficient podobnosti dvou vzorků.

zhodnocení EM metoda dosáhla indexu DICE 96,68% s výpočtovou dobou 22,72 sekund, zatímco metodika MI vykazala 96,11% a 35,13 sekund. Metoda EM dosáhla lepších výsledků [31].

5 Implementace registračních algoritmů a testování na reálných datech

V následující části práce jsou popsány základní registrační algoritmy programového prostředí MATLAB. V kapitole je uveden přehled předimplementovaných knihoven, které jsou vhodné pro registraci nejen medicínských obrazů. Některé příkazy a funkce jsou implementovány na reálná biomedicínská data a úspěšnost registrace je vyhodnocena v tabulkách. Míra podobnosti referenčního obrazu R a transformovaného plovoucího (=registrovaného) obrazu T_φ je matematicky vyjádřena evaluačními hodnotami, které jsou taktéž popsány níže.

5.1 Dostupné algoritmy v MATLABu

MATLAB má dvě předimplementované knihovny, Image Processing Toolbox a Computer Vision Toolbox. Tyto knihovny nabízejí čtyři řešení registrace obrazů:

- interaktivní registrace pomocí aplikace Registration Estimator,
- registrace snímků pomocí intenzity,
- registrace pomocí řídících bodů,
- automatické porovnávání funkcí/vlastností [39].

Tabulka 2: Tabulka funkcí, které jednotlivé řešení registrace nabízejí [40]

Funkce	Aplikace Registration Estimator	Automatická registrace založená na intenzitě	Registrace založená na řídících bodech	Automatická registrace pomocí detekce a přiřazení funkce/vlastnosti
Interaktivní registrace	✓			
Automatická registrace založená na intenzitě	✓	✓		
Automatická detekce funkcí/vlastností	✓			✓
Manuální výběr funkcí/vlastností			✓	
Automatické přiřazení funkcí/vlastností	✓		✓	✓
Nerigidní transformace	✓	✓	✓	
Automatický pracovní postup		✓		✓
Podpora 3D obrazů		✓		

5.1.1 Interaktivní registrace pomocí aplikace Registration Estimator

Aplikace Registration Estimator je vhodná pro 2D obrazy ve stupních šedi. Pokud je registrován barevný snímek, tak je nutné jeho převedení do šedé škály. Tato aplikace dokáže interaktivně porovnat techniky nerigidní, techniky založené na intenzitě a techniky založené na funkcích/vlastnostech. Výsledkem aplikace je geometrická transformace a následně registrovaný obraz [41].

Techniky založené na funkcích/vlastnostech

Aplikace nabízí několik registračních technik, pomocí kterých detekuje funkci/vlastnost shodnou v obou obrazech. Registrační techniky:

- FAST³⁵ – detekuje rohové prvky, vhodné pro scény pořízené člověkem, jako jsou ulice a místnosti.
- MinEigen – detekuje rohové prvky.
- Harris – detekuje rohové prvky, využívá efektivnější algoritmy než příkaz MinEigen.
- BRISK³⁶ – detekuje rohové prvky a na rozdíl od předchozích algoritmů podporuje změny měřítka a rotaci.
- SURF – detekuje skvrny, podporuje změny měřítka a rotaci.
- MSER³⁷ – detekuje plochu se stejnou intenzitou, podporuje změny měřítka a rotaci, je odolnější vůči afinní transformaci v porovnání s ostatními algoritmy založenými na vlastnostech.
- ORB³⁸ – detekuje rohy v rotovaných a velikostně pozměněných obrazech [42].

Techniky založené na intenzitě

Techniky založené na intenzitě korelují intenzitu obrazů v prostorové nebo frekvenční doméně. Plovoucí obraz je globálně transformován a je požadována maximalizace korelačního indexu.

Aplikace nabízí tři techniky:

- Monomodální intenzita – registrace probíhá za předpokladu, že obrazy mají podobný kontrast a jas a jsou zachyceny na stejném typu senzoru.
- Multimodální intenzita – registruje obrazy s rozdílným kontrastem a jasnem. Většinou se jedná o registraci snímků různých zobrazovacích metod (např. MRI, CT). Snímky mohou pocházet i z jednoho zařízení, ale liší se nastavenými hodnotami (např. různé nastavení expozice, různá zobrazovací sekvence).
- Fázová korelace – registruje obrazy ve frekvenční doméně. Je odolnější vůči šumu než jiné techniky založené na intenzitě. Lepších výsledků je dosaženo, pokud jsou snímky čtvercové [42].

Nerigidní registrace

Při nerigidní registraci se využívá lokální transformace. Je generováno pole posunutí funkcí, ve kterém je poloha jednotlivých pixelů v referenčním obraze mapována do plovoucího obrazu. Ten je poté zdeformován podle pole posunutí a převzorkován pomocí lineární interpolace [42].

³⁵ FAST – Features from Accelerated Segment Test.

³⁶ BRISK – Binary Robust Invariant Scalable Keypoints.

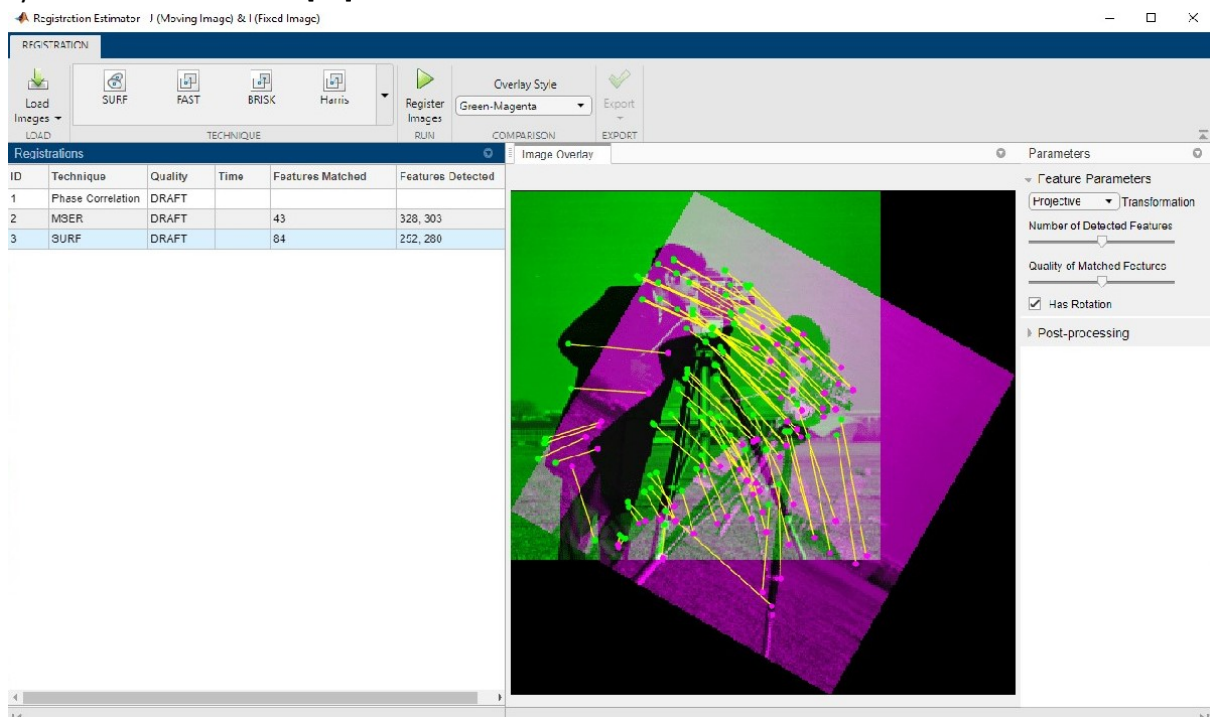
³⁷ MSER – Maximally Stable Extremal Regions.

³⁸ ORB – Oriented FAST and Rotated BRIEF.

Postup registrace pomocí aplikace Registration Estimator

Nejprve je nutné uložit do proměnných obraz referenční a obraz plovoucí. Pokud vstupním snímkům není definován počáteční odhad transformace, lze aplikaci otevřít pomocí příkazu nebo z nabídky aplikací MATLABu [43].

Snímky jsou nahrány do aplikace a vytvořeny tři techniky: fázová korelace, technika MSER, technika SURF. Tyto přednastavené techniky nalézají body společné pro referenční a plovoucí obraz. Těmto přednastaveným funkcím lze upravit nastavení nebo vybrat zcela jiné funkce. Snímky s detekovanými funkcemi/vlastnostmi se v aplikaci zobrazí. Referenční snímek je zobrazen zelenou barvou, snímek plovoucí barvou magenta. Místo, kde je hodnota intenzity obou snímků shodná, je vyznačeno barvou šedou [43].



Obrázek 24: Ukázka aplikace [43].

Tři přednastavené techniky jsou spuštěny a obrazy zaregistrovány. Po registraci je ukázán výpočetní čas a kvalita registrace, která je vyjádřena hodnotou SSIM³⁹. Čím je skóre kvality bližší hodnotě 1, tím proběhla registrace kvalitněji [43].

Po tomto registračním odhadu je vhodné upravit registrační nastavení kvality překrytí (např. zvýšit/snížit počet bodů, pomocí kterých se registrace provádí). Po nalezení nejpřesnějšího překrytí je registrovaný obraz a geometrická transformace uloženy do Workspace [43].

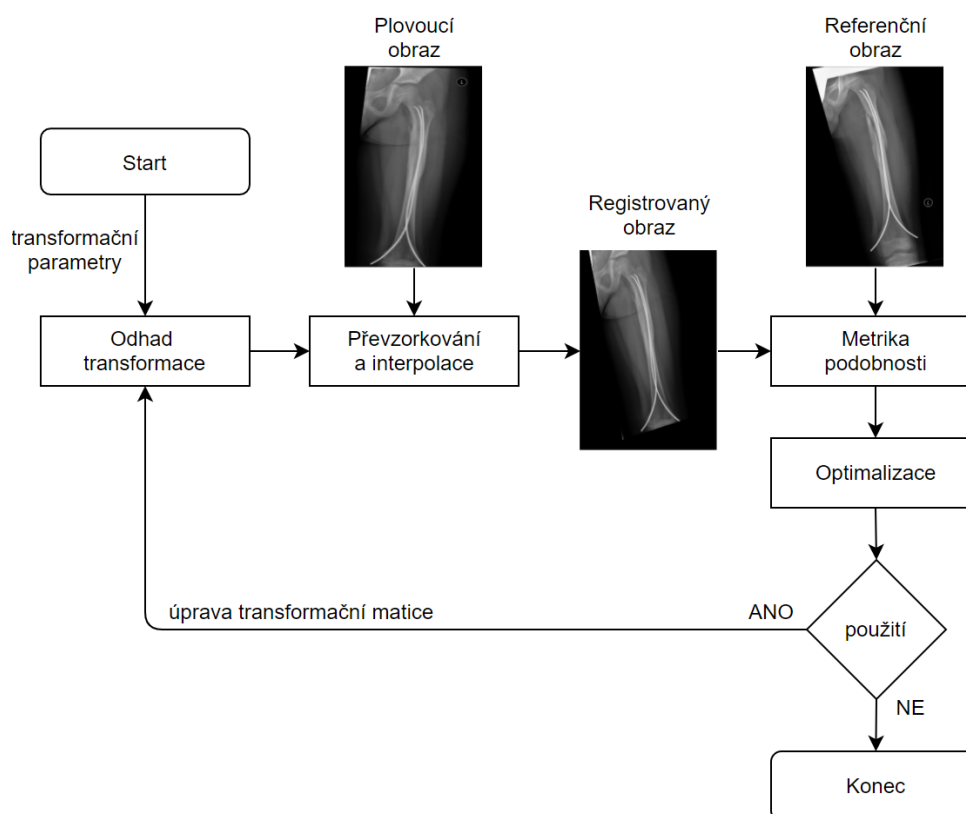
5.1.2 Automatická registrace založená na intenzitě

Tento typ registrace mapuje pixely každého snímku na základě relativní intenzity. Lze registrovat snímky různých modalit a různého počtu dimenzí. Je to výhodné pro velkou sbírku snímků. Registrace

³⁹ SSIM – Structural Similarity, strukturální podobnost.

založená na intenzitě je iterativní proces, který vyžaduje referenční a plovoucí snímek, definovat metriku podobnosti, optimalizátor a typ počáteční transformace [40].

Postup registrace založené na intenzitě



Obrázek 25: Postup registrace obrazu, zkompletováno na základě zdrojů [36][44].

Celý proces začíná typem počáteční transformace, který je zadán obsluhou, a na základě kterého je interně určena matice transformace. Transformace s interpolací je dále aplikována na plovoucí obraz. Vzniká transformovaný plovoucí obraz, jehož vlastnosti jsou porovnány metrikou podobnosti. Výsledkem je evaluační hodnota. Nakonec optimalizátor zkontroluje podmínku zastavení, která představuje všechno, co zaručuje ukončení procesu (např. dosažení nastaveného počtu iterací). Pokud není podmínka splněna, optimalizátor upraví transformační matici a zahájí celý cyklus znovu [44].

Podle toho, zda se jedná o registraci monomodální nebo multimodální, je vybrán typ metriky a optimalizátoru [45].

Tabulka 3: Metriky a optimalizátory [45]

Modalita obrazů	monomodální	Multimodální
Metrika	Mean Squares	Mattes Mutual Information
Optimalizátor	Regular Step Gradient Descent	One Plus One Evolutionary


Každá metrika a optimalizátor je definován jinými parametry a číselnou hodnotou, kterou lze nastavit a tím změnit přesnost registrace [48].

5.1.3 Registrace založená na řídicích bodech

Tento postup registruje obrazy na základě řídicích bodů, které mají společné oba obrazy. U tohoto typu registrace je dobré vědět, jakou geometrickou transformací se plovoucí snímek od referenčního odlišuje. Na základě typu transformace je v obrazech vyznačen určitý počet řídicích bodů [46].

Postup registrace založené na řídicích bodech

Do Workspace je nahrán obraz referenční a plovoucí. Interaktivně jsou vybrány řídicí body. Body mohou být přidávány, mazány a lze s nimi pohybovat. V závislosti na druhu transformace je v referenčním i plovoucím obraze nalezen různý počet párů řídicích bodů (např. u afinní transformace stačí tři páry bodů). Jedná se o vyznačení bodů společných pro oba obrázky. Z toho vyplývá, že vyznačené body v jednotlivých obrazech budou mít rozdílné souřadnice. Na základě těchto řídicích bodů jsou nalezeny parametry daného typu transformace. Následuje transformace plovoucího obrazu [46].




Obrázek 26: Výběr řídicích bodů [46].

5.1.4 Automatická registrace pomocí detekce a přiřazení funkce/vlastnosti

Tato technika registrace detekuje funkce/vlastnosti jakou jsou rohové prvky a skvrny v referenčním a plovoucím obraze a odhadne druh transformace pro nejlepší překrytí [47]. Od předchozí techniky se odlišuje tím, že společné funkce/vlastnosti si software vyhledá sám.

Postup registrace pomocí detekce funkcí/vlastností

Nejprve je nahrán referenční a plovoucí snímek do Workspace. Následuje nalezení společných funkcí/vlastností v obou obrazech, extrakce deskriptorů, spojení společných funkcí/vlastností pomocí jejich deskriptorů a načtení souřadnic odpovídajících bodů pro každý obrázek [47].



Obrázek 27: Vyznačené body [47].

Na obrázku 27 je zobrazen výsledek postupu popsaného výše. Červené značky představují detekované body v referenčním obraze, zelené značky charakterizují ty samé body ale v plovoucím obraze. Na obrázku lze pozorovat tzv. odlehle hodnoty. Jsou to takové body, jejichž párové transformační hodnoty spolu nekorrespondují. Na základě pouze korespondujících párů bodů je nalezena odpovídající transformace [47].

Výsledek registrace lze zpřesnit použitím většího množství detektorů a deskriptorů funkcí. Na tomto odkazu [52] je použit detektor BRISK a SURF.

5.1.5 Další funkce v MATLABu

Jako předpřipravení obrazu k automatické registraci může sloužit fázová korelace. V tomto případě je vykonána fázová korelace, jejíž výsledky jsou použity jako vstupní hodnoty do algoritmů založených na optimalizaci. Tyto dvě části tvoří kompletní algoritmus. Fázová korelace je vhodná pro hledání hrubého zarovnání obrazů a pro špatně zarovnatelné obrazy. Tím jsou získány dobré vstupní hodnoty algoritmů založených na optimalizaci, které poskytují přesné výsledky [53].

Na těchto odkazech [49][50][51] lze najít další základní příkazy, kterými MATLAB disponuje.

5.2 Evaluační techniky

Evaluační techniky zhodnocují kvalitu určité fáze procesu. V této práci techniky matematicky vyjadřují míru podobnosti mezi transformovaným plovoucím a referenčním obrazem. Existuje několik druhů evaluací, v práci jsou použity techniky, na jejichž hodnotě závisí pokračování procesu, a techniky, které hodnotí již výsledek procesu registrace.

Střední kvadratická chyba (MSE⁴⁰)

Střední kvadratická chyba barevného obrazu se složkami RGB je matematicky definována:

⁴⁰ MSE – Mean-squared Error.

$$MSE = \frac{\sum_z \sum_{x=1}^M \sum_{y=1}^N [R(x, y) - T_\varphi(x, y)]^2}{3 \cdot M \cdot N} \quad (5.1)$$

Střední kvadratická chyba obrazu v šedé škále je matematicky definována:

$$MSE = \frac{\sum_{x=1}^M \sum_{y=1}^N [R(x, y) - T_\varphi(x, y)]^2}{M \cdot N} \quad (5.2)$$

kde $R(x, y)$ a $T_\varphi(x, y)$ představují jasové hodnoty pixelů referenčního a registrovaného obrazu. Rozdíly jasových hodnot pixelů jsou umocněny na druhou a sečteny. Poslední operací je dělení součinem počtu řádků a sloupců referenčního obrazu, které představují proměnné M a N . Čím je MSE menší, tím jsou si obrazy podobnější [58].

Korelační koeficient (CC⁴¹)

Korelační koeficient kvantifikuje korelaci mezi pixely jednotlivých obrazů vzorcem:

$$CC = \frac{\sum_x \sum_y (R_{xy} - \bar{R}) \cdot (T_{\varphi xy} - \bar{T}_\varphi)}{\sqrt{\left(\sum_x \sum_y (R_{xy} - \bar{R})^2 \right) \cdot \left(\sum_x \sum_y (T_{\varphi xy} - \bar{T}_\varphi)^2 \right)}}, \quad (5.3)$$

$$\bar{R} = \frac{1}{a} \sum_x \sum_y R_{xy}, \quad \bar{T}_\varphi = \frac{1}{a} \sum_x \sum_y T_{\varphi xy} \quad (5.4)$$

kde x, y značí polohu řádku a sloupce (=souřadnice pixelu), R_{xy} charakterizuje hodnotu pixelu referenčního obrazu, $T_{\varphi xy}$ hodnotu pixelu registrovaného obrazu, \bar{R}, \bar{T}_φ jsou výběrové průměry pixelových hodnot jednotlivých obrazů a a počet pixelů.

Výsledek korelačního koeficientu vychází v intervalu $\langle 0, 1 \rangle$. Čím má korelační koeficient vyšší hodnotu, tím je podobnost mezi obrazy vyšší, např. pokud $CC = 1$, znamená to, že mezi obrazy existuje lineární vztah a jsou si maximálně podobné [59].

Strukturální podobnost (SSIM)

Strukturální podobnost je metoda, která předpovídá vnímané kvality obrazu. Výpočet zahrnuje výpočet jasové složky l , výpočet kontrastu c a struktury s . Matematicky je $SSIM$ definována:

$$SSIM(R, T_\varphi) = [l(R, T_\varphi)]^\alpha \cdot [c(R, T_\varphi)]^\beta \cdot [s(R, T_\varphi)]^\gamma, \quad (5.5)$$


⁴¹ CC – Correlation coefficient.

$$l(R, T_\varphi) = \frac{2\mu_R\mu_{T_\varphi} + C_1}{\mu_R^2 + \mu_{T_\varphi}^2 + C_1}, c(R, T_\varphi) = \frac{2\sigma_R\sigma_{T_\varphi} + C_2}{\sigma_R^2 + \sigma_{T_\varphi}^2 + C_2}, s(R, T_\varphi) = \frac{\sigma_{RT_\varphi} + C_3}{\sigma_R\sigma_{T_\varphi} + C_3}, \quad (5.6)$$

$$\sigma_{RT_\varphi} = \frac{1}{N-1} \sum_{x,y=1}^N (R_{xy} - \mu_R)(T_{\varphi xy} - \mu_{T_\varphi}), \quad (5.7)$$

kde μ_R, μ_{T_φ} je průměr všech pixelových hodnot v referenčním obraze R nebo registrovaném obraze T_φ , $\sigma_R, \sigma_{T_\varphi}$ je směrodatná odchylka všech pixelových hodnot daných obrazů a C jsou konstanty.

$SSIM$ nabývá hodnot v intervalu $\langle 0, 1 \rangle$, hodnota 1 vyjadřuje maximální shodu obou obrazů. Na obrázku 28 představují tmavé pixely oblasti, kde je velký rozdíl mezi referenčním a transformovaným plovoucím obrazem, lokální hodnoty $SSIM$ jsou malé. Naopak světlé pixely reprezentují shodné oblasti pro oba obrazy. Lokální hodnoty $SSIM$ jsou vysoké [60].



Obrázek 28: Ukázka SSIM, snímek klíční kosti, zdroj vlastní.

Euklidovská vzdálenost (PDIST⁴²)

Euklidovská vzdálenost počítá vzdálenost odpovídajících pozic vektorů referenčního a registrovaného obrazu. Matematicky je definována:


$$pdist_{RT_\varphi} = \sqrt{(x_R - x_{T_\varphi})^2 + (y_R - y_{T_\varphi})^2}, \quad (5.8)$$

kde x, y představují vektory jednotlivých obrazů. Výsledkem je matice hodnot, ze které byl pro účely následujícího úkolu vypočítán průměr. Čím je hodnota vyšší, tím je shoda obrazů menší [61].

5.3 Registrace obrazu pomocí rotace

Registrace obrazu byla provedena se snímky sítnice (lat. retiny) předčasně narozených dětí, u kterých je velmi velká pravděpodobnost výskytu zrakové vady.

⁴² PDIST – Pairwise distances.



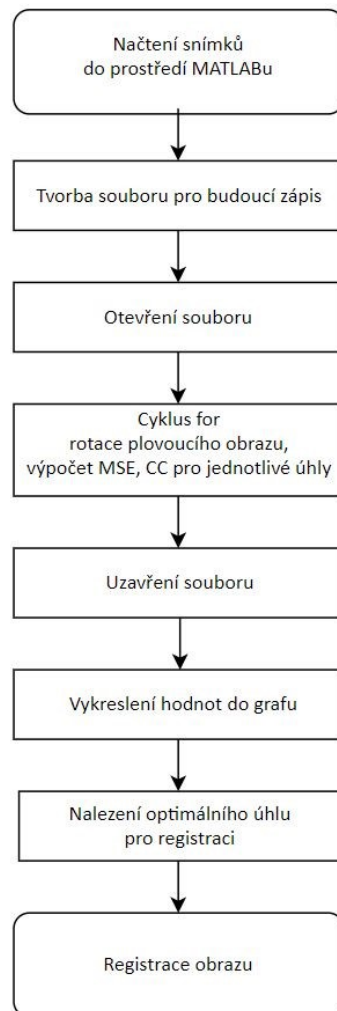
Obrázek 29: Popis sítnice, zdroj vlastní.

Snímky byly poskytnuty vedoucím práce. K dispozici bylo 63 barevných snímků o celkové velikosti 63 MB. Všechny obrazy v datasetu mají rozměry 640×480 pixelů a jsou formátu .jpg.

Během jednotlivých kontrol bylo pořízeno šesti pacientům několik snímků. Snímky snímaly stejnou scénu, byly však otočené o určitý úhel. U každého pacienta byl vybrán jeden referenční snímek, vůči kterému byl plovoucí snímek rotován. Úkolem bylo zjistit úhel otočení pro nejlepší registraci obrazů. Pro každý úhel byla pomocí iteračního cyklu *for* zaznamenána míra podobnosti mezi referenčním a rotovaným plovoucím obrazem. Míra podobnosti obrazů byla zjišťována pomocí dvou evaluačních technik, střední kvadratické chyby (MSE) a korelačního koeficientu (CC). Tam, kde byly hodnoty optimální, byl ideální úhel rotace, a registrace obrazu by měla být nejpřesnější.

5.3.1 Detailní popis úlohy


Jednotlivé kroky registrační procedury lze vidět na obrázku 30:



Obrázek 30: Vývojový diagram úlohy, zdroj vlastní.

Vybrané snímky retiny byly nahrány funkcí `imread(image.jpg)` do prostředí MATLABu. Dále byly vytvořeny soubory ve formátu `.csv` pro zápis hodnot MSE a CC při jednotlivých úhlech natočení. Tyto vytvořené soubory byly otevřeny pomocí funkce `fopen(result.csv, 'a')`, poté následoval cyklus `for`. Pomocná proměnná `angle` představovala úhel rotace. Pomocí cyklu `for` byl snímek otáčen o 360 stupňů s krokem 1. Cyklus obsahoval tři hlavní příkazy, `imrotate()`, `immse()` a `corr2()`. Příkaz `imrotate()` tvořil jádro celého cyklu. Pomocí této funkce byl plovoucí obraz natočen proti směru hodinových ručiček podle osy otáčení, která procházela středem obrazu. Matice rotace M_{rot} obsahuje úhel θ , který charakterizovala proměnná `angle`.

$$M_{rot} = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \quad (5.9)$$



Obrázek 31: Rotace snímku, vlevo referenční obraz, vpravo plovoucí obraz s úhlem otočení 60 stupňů, zdroj vlastní.

Příkazem `immse()` byla vypočtena střední kvadratická chyba. Příkaz `corr2()` vypočítal dvourozměrný korelační koeficient mezi dvěma obrazovými maticemi, výsledek byl datového typu `double`. Výsledné hodnoty CC jsou v procentech, proto byl celý příkaz vynásoben 100. Následovalo uložení všech takto vypočtených hodnot a úhlů do proměnné `table` a zápis do souboru. Důležitým krokem bylo navyšování úhlu. Poté byl cyklus ukončen a soubor pro zápis uzavřen.

Zdrojový kód:

```
fixed_image = imread('ref_image_1.jpg'); %nahrání referenčního snímku
moving_image = imread('mov_image_1.jpg'); %nahrání plovoucího snímku

file = fopen('result_1.csv','a'); %otevření souboru
fprintf(file, '%4s %3s %2s\n', 'UHEL;', 'MSE;', 'IC'); %vypsání úhlu, MSE, IC

angle=1;%pomocná proměnná
for i = 1:1:360
    rotate_image = imrotate(moving_image, angle , 'bicubic','crop');
    %rotace snímku o určitý úhel; bicubic=bikubická interpolace;
    crop=zachování rozměru s referenčním obrazem, nutné pro výpočet MSE a CC
    MSE = immse(rotate_image, fixed_image); %výpočet MSE
    CC = 100*(corr2(rotate_image(:), fixed_image(:))); %výpočet CC
    table = [angle; MSE; CC]; %uložení do proměnné table
    fprintf(file, '%3d; %5.3f; %2.3f\n',table); %zápis do souboru
    angle = i + 1; %navyšování úhlu
end %ukončení cyklu
fclose(file); %uzavření souboru
```

5.4 Implementace registrace založené na intenzitě

Registrace obrazu byla provedena se snímky z datasetů, které byly poskytnuty vedoucím práce. První dataset obsahoval RTG snímky dolních končetin, zejména stehenních kostí (lat. femur), a snímky horní části těla, zejména klíčních kostí (lat. scapula). K dispozici bylo 202 snímků klíčních kostí a 383 snímků stehenních kostí o celkové velikosti 5,7 GB. Obrazy jsou formátu DICOM, mají různé rozměry a jsou v šedé škále. Druhá datová sada obsahovala 218 snímků o celkové velikosti 478 MB a rozměrech 2912×2912 pixelů. Snímky zobrazují sítnici, jsou formátu .jpg a v RGB barvách, proto bylo pro tuto úlohu nutné převedení do šedé škály.

Snímky byly pořízeny pacientům s frakturou, jejichž zlomenina byla vyztužena dráty a šrouby. Pacienti poté docházeli na pravidelné kontroly a byly pořízeny další snímky. První pořízený snímek byl zvolen jako referenční a další snímky z kontrol jako plovoucí. Účelem registrace bylo zjištění aktuálního stavu kosti a její hojení.

Pro registraci založenou na intenzitě je nutné definování metriky podobnosti, optimalizátoru a typy počáteční transformace.

5.4.1 Metrika podobnosti

V případě multimodální registrace MATLAB aplikuje metriku podobnosti Mattes Mutual Information MMI, která využívá po dobu registrace jednu sadu prostorových vzorků namísto použití nové sady pro každou iteraci. V tom je jeden z hlavních rozdílů mezi MMI a MI. Použití stejné sady má za následek přesnější nákladovou funkci. Vlastnosti jednotlivých vzorků jsou hodnoceny pomocí sdruženého histogramu [55].

Nastavitelné parametry metriky:

- Počet prostorových vzorků použitých k výpočtu metriky vzájemné informace (NSS⁴³) – výchozí hodnota je 500. Výsledky registrace jsou přesnější, pokud je tato hodnota zvyšována. Roste ale výpočetní náročnost.
- Počet intervalů histogramu (NHB⁴⁴) – výchozí hodnota je 50, minimum 5.
- Možnost zahrnout při výpočtu metriky všechny pixely z překrývajících se oblastí (UP⁴⁵). Pokud je nastavena hodnota 0=false, tak výsledky nemusí být reprodukovatelné, protože funkce vybere náhodnou podmnožinu pixelů. Proto je defaultní hodnota 1=true [55].

5.4.2 Optimalizátor

„One plus One Evolutionary“ mění parametry transformační matice do té doby, než je ukončen stopovým prvkem. Změna transformační matice probíhá pomocí tzv. rodiče a potomka. Poslední iterace, která proběhla za určitých podmínek, je brána jako rodič. Její hodnoty jsou rušeny a mutovány. Pokud takto vzniklé hodnoty (potomek) přinesou lepší výsledky podobnosti, tak se iterace stává

⁴³ NSS – Number of Spatial Samples.

⁴⁴ NHB – Number of Histogram Bins.

⁴⁵ UP – Use all Pixels.

rodičem. Takové změny parametrů jsou velmi agresivní. Pokud rodič vykáže lepší výsledky než potomek, znamená to příliš velkou změnu parametrů a další změna parametrů je menší [57].

Nastavitelné parametry optimalizátoru:

- Růstový faktor poloměru vyhledávání (GF^{46}) – určuje efektivitu a správnost optimalizace. Poloměr vyhledávání je vyhledávací prostor všech bodů, který je definován parametry nákladové funkce. Hodnota růstového faktoru má za následek mutace rodičovských iterací. Představuje, jakým krokem jsou hodnoty rodičů měněny. Čím je hodnota faktoru vyšší, tím je optimalizace rychlejší, ale může vést k nalezení pouze lokálních extrémů metriky. Je-li nastavena nižší hodnota faktoru, je delší výpočetní čas, ale může směřovat k lepšímu řešení. Hodnota GF musí být větší než 1. MATLAB má defaultní hodnotu 1,05.
- Epsilon (E) – minimální hodnota poloměru vyhledávání. Kontroluje přesnost konvergence úpravou minimální velikosti poloměru vyhledávání. Pokud je hodnota Epsilonu malá, optimalizace metriky je přesnější, ale výpočetní čas delší. Při nastavení vyšší hodnoty Epsilonu se výpočetní čas sníží na úkor přesnosti. Defaultní hodnota je $1,5 \cdot 10^{-6}$.
- Počáteční hodnota poloměru vyhledávání (IR^{47}) – při nastavení velké hodnoty je doba výpočtu nízká. Příliš velké hodnoty mohou mít za následek optimalizaci, která nebude konvergovat. Přednastavená hodnota v MATLABu je $6,25 \cdot 10^{-3}$.
- Maximální počet ($MaxI^{48}$) opakování optimalizátoru na dané úrovni pyramid. Úroveň pyramid si lze představit jako 2 vrstvy obrazu, vrstvu pixelovou a vrstvu obsahující pixelovou mřížku. Vrstva s pixelovou mřížkou je rozdělena na několik čtverců a každý čtverec je v další vrstvě pyramid rozdělen na stejný počet čtverců jako v kroku předtím. Takto to probíhá až do dosažení zvolené úrovně pyramid. Výchozí hodnota je 100 [56][57][62].

⁴⁶ GF – Growth Factor.

⁴⁷ IR – Initial Radius.

⁴⁸ MaxI – Maximum Iterations.

5.4.3 Detailní popis úlohy

Jednotlivé kroky úlohy lze vidět na obrázku 32.



Obrázek 32: Vývojový diagram úlohy, zdroj vlastní.

Úkolem úlohy bylo seznámení s parametry optimalizátoru a metriky a nalezení optimálních hodnot tak, aby míra podobnosti snímků byla co nejvyšší. Prvotní představa o zadání vstupních hodnot byla kombinace pěti různých hodnot pro šest vstupních parametrů a kombinace dvou hodnot pro parametr *UP*. Tento požadavek obnášel počet kombinací rovnající se 2×5^6 , tj. 31 250 různých kombinací. Výpočet jedné kombinace trvá průměrně 10–20 minut, proto by realizace výpočtu 31 250 kombinací byla velmi výpočetně náročná a časově nerealizovatelná. Bylo přistoupeno k jednoduššímu řešení, kdy vstupní hodnoty byly tvořeny kombinacemi tří různých hodnot pro šest parametrů a kombinací dvou hodnot pro *UP*. Tímto způsobem vzniklo 1458 kombinací, které byly zkompletovány pomocí excelu a následně nahrány do MATLABu. Hodnoty vstupních parametrů, se kterými bylo provedeno prvotní testování, je uvedeno v tabulce 4:

Tabulka 4: Hodnoty tvořící kombinace vstupních parametrů, zdroj vlastní

Hodnota	NSS	NHB	UP	GF	E	IR	Maxl
č. 1	300	30	1=true	1,05	$1,5 \cdot 10^{-9}$	$6,30 \cdot 10^{-7}$	100
č. 2	700	70	0=false	1,15	$7,5 \cdot 10^{-6}$	$3,13 \cdot 10^{-3}$	700
č. 3	1 100	110		1,25	$1,5 \cdot 10^{-5}$	$6,30 \cdot 10^{-3}$	1 300

V následujících krocích byly výsledky vyhodnoceny a byla provedena korekce vstupních hodnot v očekávání lepších evaluačních výsledků. Rozsahy některých parametrů byly rozšířeny. Výstupy s hodnotou $UP = 0$ byly vyloučeny. Byla nadefinována nová sada kombinací, které vycházely z první série výsledků, tedy z 1458 kombinací.

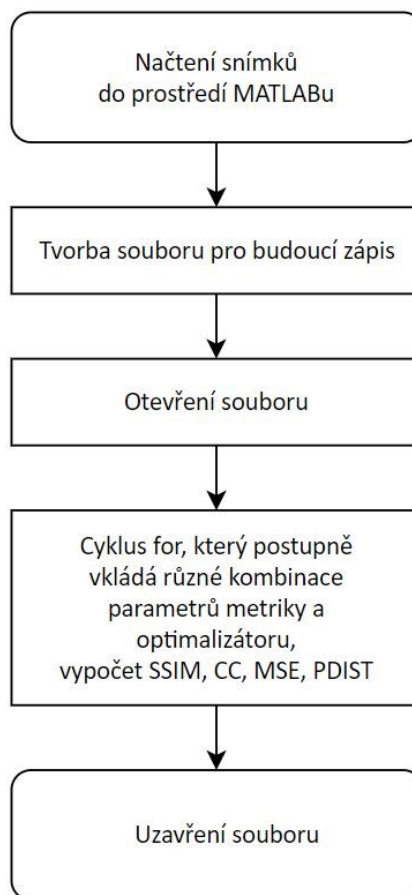
Hodnoty vstupních parametrů po korekci jsou uvedeny v tabulce 5:

Tabulka 5: Hodnoty tvořící kombinace vstupních parametrů po korekci, zdroj vlastní

Hodnota	NSS	NHB	UP	GF	E	IR	Maxl
č. 1	300	30	1=true	1,0001	$1,5 \cdot 10^{-9}$	$6,3 \cdot 10^{-7}$	100
č. 2	700			1,0500	$1,5 \cdot 10^{-6}$		700
č. 3	1 100			1,1500	$1,5 \cdot 10^{-5}$		1 300
č. 4	5 000			1,2500	$1,5 \cdot 10^{-4}$		10 000
č. 5					$7,5 \cdot 10^{-6}$		

Nově nadefinována sada měla 75 kombinací vstupních hodnot, které byly testovány na 20 dvojicích snímků. Z výsledků evaluačních hodnot těchto snímků bylo vybráno optimální nastavení, které bylo aplikováno na ostatní snímky z datasetů.

5.4.4 Proces MATLABu



Obrázek 33: Vývojový diagram postupu v MATLABu, zdroj vlastní.

Celý proces v MATLABu začínal načtením referenčního a plovoucího snímku. Počáteční transformace, která je zadána obsluhou, a na základě které je interně určena matice transformace, byla afinní. Transformace s interpolací byla dále aplikována na plovoucí obraz. Vznikl transformovaný plovoucí obraz, jehož vlastnosti byly porovnány metrikou podobnosti. Metrika podobnosti využívala prostorové vzorky (pixels), jejichž vlastnosti jsou hodnoceny pomocí histogramu. Nakonec optimalizátor zkontroloval podmínku zastavení. Pokud nebyla podmínka splněna, optimalizátor upravil transformační matici a zahájil celý cyklus znovu.


Všechny kombinace parametrů a výsledky evaluačních hodnot byly zapsány do souboru formátu .csv a uchovány pro pozdější použití.

6 Analýza výsledků

Tato kapitola je věnována výsledkům proběhlých registrací uvedených v kapitolách 5.3 a 5.4. Veškeré výsledky jsou součástí příloh.

6.1 Výsledky registrace pomocí rotace

K dispozici byla data šesti pacientů. Snímky, se kterými byla úloha prováděna, byly náhodně selektovány buď v rámci jedné kontroly, nebo z více kontrol. Celkem bylo vybráno 18 plovoucích snímků. Pro 14 snímků byl nalezen úhel natočení pro optimální registraci. Jednalo se o snímky, kde byla v určitém úhlu natočení hodnota korelačního koeficientu maximální a zároveň hodnota střední kvadratické chyby minimální. Grafická závislost evaluací na úhlu otočení je na obrázku 34. Výsledky jsou shrnuty v následujících tabulkách. Zbylým čtyřem snímkům optimální úhel registrace nalezen nebyl. V těchto případech se neshodoval maximální korelační koeficient a minimální střední kvadratická chyba. Proto byly tyto obrazy vyřazeny ze statistiky a dále se jim budu věnovat v kapitole Diskuze a vyhodnocení výsledků práce.



Obrázek 34: Grafická závislost evaluačních hodnot jednoho referenčního a transformovaného plovoucího obrazu, zdroj vlastní.

Tabulka 6: Tabulka vybraných hodnot, zdroj vlastní

Referenční snímek	Plovoucí snímek	max. CC (%)	min. MSE (-)	Úhel optimální registrace (°)
č. 1	č. 1	99,325	39,048	0
č. 1	č. 2	98,893	65,293	0
č. 2	č. 1	83,143	2443,566	0
č. 2	č. 2	91,064	1261,946	0
č. 2	č. 4	93,444	682,044	0
č. 2	č. 5	89,943	1191,173	0
č. 2	č. 6	86,627	1324,924	0
č. 2	č. 7	85,232	1606,700	180
č. 3	č. 1	99,185	87,492	0
č. 5	č. 1	93,108	1093,457	180
č. 5	č. 2	94,485	660,216	0
č. 5	č. 3	89,684	915,710	180
č. 6	č. 1	88,547	1007,964	0
č. 6	č. 2	89,661	868,613	359
průměr:		91,596	946,296	64,214

Z naměřených dat vyplývá, že průměrná maximální hodnota korelačního koeficientu je **91,6 %**, minimální hodnota střední kvadratické chyby je **946,3** a průměrný optimální úhel natočení **64,2 stupňů**. Optimální úhel s nejvyšší četností je však **0 stupňů**. Tzn., že plovoucí snímek nebylo nutné vůči referenčnímu otáčet.

Dále je uvedena tabulka 7, názorná registrace obrazu (obrázek 35) a výsledná registrace pro čtyři snímky (obrázek 36), jejichž evaluační charakteristiky dosáhly nejlepších hodnot a míra podobnosti mezi obrazy je z celé úlohy nejvyšší.


Následuje tabulka 8 a registrace snímků (obrázek 37), jejichž evaluační techniky vykazují z celé úlohy nejmenší míru podobnosti.

Tabulka 7: Tabulka nejlepších hodnot, zdroj vlastní

Referenční snímek	Plovoucí snímek	max. CC (%)	min. MSE (-)	Úhel optimální registrace (°)	Obrázek 36
č. 1	č. 1	99,325	39,048	0	a)
č. 1	č. 2	98,893	65,293	0	b)
č. 3	č. 1	99,185	87,492	0	c)
č. 5	č. 2	94,485	660,216	0	d)
průměr:		97,972	213,012	0	



Obrázek 35: Registrace obrazu v detailu, zdroj vlastní.



Obrázek 36: Registrace snímků s nejlepšími hodnotami evaluačních technik.


Registrace a) referenční snímek č. 1, plovoucí snímek č. 1; b) referenční snímek č. 1, plovoucí snímek č. 2; c) referenční snímek č. 3, plovoucí snímek č. 1; d) referenční snímek č. 5, plovoucí snímek č. 2, zdroj vlastní.

Na všech snímcích lze pozorovat mírně odlišnou polohu sítnicových cév. Nejmenší jsou tyto odchylky na snímcích a) a b). Optické disky se na snímcích a), b), d) překrývají. Na snímku c) je odlišná poloha papily znatelnější.


Tabulka 8: Tabulka nejhorších hodnot, zdroj vlastní

Referenční snímek	Plovoucí snímek	max. CC (%)	min. MSE (-)	Úhel optimální registrace (°)	Obrázek 37
č. 2	č. 1	83,143	2443,566	0	a)
č. 2	č. 7	85,232	1606,700	180	b)
č. 2	č. 6	86,627	1324,924	0	c)
č. 6	č. 1	88,547	1007,964	0	d)
průměr:		85,887	1595,789	45	

a)




b)



c)



d)



Obrázek 37: Registrace snímků s nejhoršími hodnotami evaluačních technik.

Registrace a) referenční snímek č. 2, plovoucí snímek č. 1; b) referenční snímek č. 2, plovoucí snímek č. 7; c) referenční snímek č. 2, plovoucí snímek č. 6; d) referenční snímek č. 6, plovoucí snímek č. 1, zdroj vlastní.

Za povšimnutí stojí obrázek a), kde i přesto, že je jeden snímek focen, kdy se pacient dívá rovně před sebe, a druhý snímek, kdy se dívá vpravo, byl nalezen optimální úhel registrace. Další snímky vykazují znatelné rozdíly v polohách papil i sítnicových cév.


6.2 Výsledky registrace založené na intenzitě

K dispozici byly snímky tří různých datasetů. První test byl proveden s RTG snímky scapuly. Na jedné dvojici snímků bylo otestováno 1458 různých kombinací vstupních parametrů. Z těchto výsledků bylo zjištěno, že kombinace s parametrem $UP=0$ (false) nelze použít. Evaluační hodnoty pro toto nastavení vykazovaly ve srovnání s hodnotou $UP=1$ řádově horší hodnoty a vazba na hodnotu parametru byla nestabilní. Dále bylo zjištěno, že hodnoty NSS neovlivní evaluační hodnotu a hodnoty E závisí na velikosti GF a $MaxI$. Pokud je $GF=1,05$, parametr E výsledek neovlivní. Po zvýšení parametru $GF=1,15$ nebo $GF=1,25$ parametr E při počtu iterací 1 300 výsledek evaluačních hodnot ovlivňuje. Výsledek je možné vidět v tabulce 9:


Tabulka 9: Ukázka deseti kombinací parametrů, zdroj vlastní

NSS	NHB	UP	GF	E	IR	MaxI	SSIM (-)	CC (-)	MSE (-)	PDIST (-)
300	30	1	1,05	$7,5 \cdot 10^{-6}$	$3,13 \cdot 10^{-3}$	1 300	0,91966	0,74873	605 698	47 698
300	30	1	1,05	$1,5 \cdot 10^{-5}$	$3,13 \cdot 10^{-3}$	1 300	0,91966	0,74873	605 698	47 698
700	30	1	1,05	$1,5 \cdot 10^{-9}$	$3,13 \cdot 10^{-3}$	1 300	0,91966	0,74873	605 698	47 698
700	30	1	1,05	$7,5 \cdot 10^{-6}$	$3,13 \cdot 10^{-3}$	1 300	0,91966	0,74873	605 698	47 698
300	30	1	1,15	$7,5 \cdot 10^{-6}$	$6,30 \cdot 10^{-3}$	700	0,91961	0,74857	606 139	47 700
300	30	1	1,15	$1,5 \cdot 10^{-5}$	$6,30 \cdot 10^{-3}$	700	0,91961	0,74857	606 139	47 700
300	30	1	1,15	$1,5 \cdot 10^{-4}$	$6,30 \cdot 10^{-7}$	1 300	0,91813	0,81278	460 585	44 470
300	30	1	1,15	$1,5 \cdot 10^{-6}$	$6,30 \cdot 10^{-7}$	1 300	0,91470	0,80624	478 090	44 248
300	30	1	1,25	$1,5 \cdot 10^{-4}$	$6,30 \cdot 10^{-7}$	1 300	0,91924	0,81077	463 357	44 694
300	30	1	1,25	$1,5 \cdot 10^{-6}$	$6,30 \cdot 10^{-7}$	1 300	0,90197	0,77453	553 158	45 859

Se získanými výsledky z této procedury byla provedena korekce, na základě které vzniklo 75 kombinací vstupních parametrů. Rozložení vstupních hodnot a výsledků evaluačních hodnot před korekcí a po korekci, je ukázáno pomocí krabicových grafů:



Obrázek 38: Krabicové grafy s kombinacemi před korekcí, zdroj vlastní.



Obrázek 39: Krabicové grafy s kombinacemi po korekci, zdroj vlastní.


Z grafů je patrné, že korekce hodnot parametrů vedla k odstranění odlehlých hodnot u evaluačních technik.

Vzniklé kombinace upravené korekcí byly testovány na 20 dvojicích snímků. Osm testování proběhlo se snímky scapuly pacienta A a B. Výsledky evaluačních hodnot pacienta A měly velký rozdíl mezi největšími a nejmenšími hodnotami pozorovaných evaluačních hodnot. Bylo to způsobeno tím, že obrazy si nebyly příliš podobné. U Pacienta B evaluační hodnoty takového rozdílu nedosahovaly. Všechny vstupní kombinace dávaly spolehlivé výstupy a výsledek ovlivňovaly jen minimálně.

K minimálnímu vlivu vstupních parametrů docházelo také při testování deseti snímků retiny, kdy podobnost snímků byla velmi vysoká.

Další dvě testování proběhla se snímky femuru. Snímky si nebyly příliš podobné a výsledky vykazovaly velký interval jednotlivých evaluačních technik. Z výsledků vyplynulo, že volba vstupních parametrů závisí na podobnosti obrazů. V případě velké podobnosti obrazů všechny vstupy dávaly spolehlivé výstupy a rozdíly evaluačních technik byly u jednotlivých kombinací téměř zanedbatelné.

Jelikož byly použity čtyři evaluační hodnoty jako ukazatel podobnosti, byla všem čtyřem evaluačním hodnotám přikládána stejná významnost v určení optimální kombinace parametrů. Ve většině případů nastaly situace, kdy podle každé evaluační hodnoty byla optimální jiná kombinace hodnot. Proto konečné vyhodnocení proběhlo na základě vlastního tzv. Top indexu. V každém souboru se 75 kombinacemi parametrů byly definovány krajní meze evaluačních hodnot. Evaluační hodnoty byly přeindexovány mezi hodnotu 0 a 1. Významnost každého evaluačního parametru byla 0,25. Součin všech evaluačních parametrů přes definovanou významnost je již zmíněný Top index. Top index jednotlivých kombinací v závislosti na počtu úloh byl vyneseno do grafu, který napomohl k vizuálně přehlednějšímu výběru optimálního nastavení.



Obrázek 40: Grafické zobrazení Top indexu, zdroj vlastní.

Optimální nastavení vstupních parametrů, které by mělo po aplikaci na jakýkoliv typ obrazu poskytnout uspokojivý výsledek, odpovídá v grafu kombinaci č. 50 a je uvedeno v následující tabulce:


Tabulka 10 :Optimální nastavení, zdroj vlastní

NSS	NHB	UP	GF	E	IR	MaxI
300	30	1	1,15	$1,5 \cdot 10^{-6}$	$6,3 \cdot 10^{-7}$	1 300

Optimální nastavení bylo aplikováno celkem na 193 dvojic snímků, jednalo se o 15 snímků retiny, 46 snímků horních končetin a 132 snímků dolních končetin. Výsledné evaluační hodnoty jsou zaznamenány v následující tabulce a výsledky vyneseny do grafu.


Tabulka 11: Výsledné hodnoty evaluací, zdroj vlastní

Typ snímků	Počet snímků	Průměrná hodnota SSIM (-)	Průměrná hodnota CC (-)	Průměrná hodnota MSE (-)	Průměrná hodnota PDIST (-)
Retina	15	0,8586	0,6998	1 070 470	49 522
RTG horní část	46				
RTG dolní část	132				



Obrázek 41: Krabicové grafy s rozložením evaluačních hodnot, zdroj vlastní.


Z tabulky a grafů jsou patrné průměrné hodnoty evaluačních technik. V porovnání s krabicovými grafy na obrázku 39 bohužel došlo ke zhoršení průměrných hodnot jednotlivých evaluací.




Obrázek 42: Závislost evaluačních technik, zdroj vlastní.

Na obrázku 42 je zobrazena závislost evaluačních technik ze 193 aplikací. Z průběhu křivek jsou zjevné podobné průběhy křivek *SSIM* a *CC* a podobné tendence křivek *MSE* a *PDIST*. Hodnoty evaluací *SSIM* jsou v intervalu (0,6;1,0). Hodnoty *CC* pokrývají celý interval (0;1). Hodnoty *MSE* a *PDIST* taktéž zahrnují široký rozptyl hodnot. Většina hodnot u *MSE* se nachází v rozmezí hodnot (0;10000000) a hodnoty *PDIST* v rozmezí (0;100000).


Následující snímky zobrazují výsledky aplikace optimálního nastavení. V obrazové matici se nachází referenční snímek, plovoucí snímek, registrovaný snímek a barevně rozlišitelné snímky (referenční a registrovaný).



Obrázek 43: Aplikace optimálního nastavení na snímky retiny, zdroj vlastní.



Obrázek 44: Aplikace optimálního nastavení na RTG snímky, zdroj vlastní.



Obrázek 45: Aplikace optimálního nastavení na RTG snímky femuru, zdroj vlastní.

7 Diskuze a vyhodnocení výsledků práce

Úkolem bakalářské práce bylo prostudování základních metod registrace obrazu a jejich následná implementace na reálné obrazové snímky. Během studování různých literárních pramenů bylo zjištěno, že registrace obrazu je složitá operace obsahující vysoký počet metod. K pochopení dané problematiky, metod a termínů s registrací souvisejících, je nutné nastudování velkého množství literatury. Je tedy velmi náročné uvést čtenáře do této oblasti, aniž by nebyly vysvětleny určité pojmy.

V praktické části byly na medicínská data implementovány dvě metody registrace, a to registrace geometrickou transformací a registrace založená na intenzitě. Úkolem bylo nalezení parametrů transformace pro nejpresnější registraci.

Registrace obrazu využívající pouze rotaci, je v praxi využitelná pro obrazová data, která snímají téměř stejnou scénu, kterou je nutné rigidní transformací upravit pro přesné slícování.

Registrací pomocí rotace bylo úkolem zjistit optimální úhel otočení plovoucího snímku, který byl rotován v rozsahu 1–360 stupňů. Celá úloha probíhala v prostředí MATLAB, kde byl naprogramován cyklus, který daný snímek otáčel o jednotlivé stupně, a ke každému stupni zapisoval míru podobnosti mezi referenčním a rotovaným obrazem. Míra podobnosti byla matematicky vyjádřena pomocí korelačního koeficientu a střední kvadratické chyby. Úloha byla testována na 18 dvojicích snímků, které byly pořízeny pacientům v rámci jedné lékařské kontroly nebo během více kontrol. Dalo by se předpokládat, že snímky pořízené u pacienta v několika termínech, budou vykazovat menší podobnost. Mezi nejlepšími hodnotami evaluací se však umístila registrace složená z obrazů pořízených v různých datech. Jednalo se s největší pravděpodobností o výjimku, neboť čtyři nejhorší evaluace byly tvořeny právě snímky pořízenými v různých termínech. U 14 dvojic snímků byl nalezen optimální úhel rotace. Jednalo se o snímky, kde byla v určitém úhlu natočení hodnota korelačního koeficientu maximální a zároveň hodnota střední kvadratické chyby minimální. Není pravidlem, aby při maximální hodnotě korelačního koeficientu byla minimální střední kvadratická chyba. Tato situace nastala u čtyř případů, kdy se nepodařilo najít optimální úhel registrace. Výsledky lze vidět v následující tabulce:

Tabulka 12: Tabulka vyřazených hodnot, zdroj vlastní

Referenční snímek	Plovoucí snímek	max. CC (%)	min. MSE (-)	Úhel optimální registrace (°)
č. 2	č. 3	83,072	2583,948	neshoda, 180, 216
č. 3	č. 2	85,757	1712,701	neshoda, 180, 264
č. 4	č. 1	90,815	883,172	neshoda, 360, 330
č. 4	č. 2	90,867	870,304	neshoda, 360, 338

Pro registraci těchto čtyř případů navrhuji udělat registrace v obou zjištěných úhlech a následně by bylo rozhodnuto, která registrace je vhodnější a užitečnější pro následné použití.

Registrace založená na intenzitě je vhodná pro registraci snímků různých modalit, různého počtu dimenzí a pro velkou sbírku snímků. Cílem úlohy bylo zjistit optimální nastavení vstupních parametrů. Vzhledem k časové náročnosti byl prvotní předpoklad testovaných hodnot upraven. Po prvotním otestování 1458 kombinací bylo zjištěno, že kombinace s parametrem $UP=0$ (false) nelze použít, protože zahrnují výpočet náhodné množiny pixelů, což má za následek nestabilní výsledné hodnoty. Dalším poznatkem bylo, že vztah daného parametru na přesnost výpočtu a zlepšení evaluačních hodnot nebyla u některých vstupních parametrů potvrzena. Posledním zjištěním byla závislost parametru E na velikosti GF a $MaxI$.

Při vyhodnocení souborů s výsledky 75 kombinací všech 20 dvojic byly zjištěny následující poznatky. Pokud je $GF=1,0001$, parametr E výsledek neovlivní. Při hodnotě $GF=1,05$ je výsledek parametrem E ovlivněn pouze při $MaxI=10000$. Po zvýšení parametru $GF=1,15$ nebo $GF=1,25$ parametr E ovlivní výsledek již při počtu iterací 1 300. Ovlivnění výsledku parametrem E při daných GF a $MaxI$ však není pravidelné. Nastaly situace, kdy všechny parametry byly totožné, lišily se pouze parametrem E a výsledek byl ve všech situacích stejný. Dále bylo zjištěno, že čím nižší hodnota parametru E , tím lepší hodnoty evaluačních hodnot. Stejných hodnot evaluací lze dosáhnout při velké $MaxI$ a zároveň velmi malém E .

Z výsledků vyplynulo, že volba vstupních parametrů závisí na podobnosti obrazů. V případě velké podobnosti obrazů všechny vstupy dávaly spolehlivé výstupy a rozdíly evaluačních technik byly u jednotlivých kombinací téměř zanedbatelné.

Prvotním předpokladem vyhodnocení optimálního nastavení bylo, že všechny čtyři evaluační techniky potvrdí jedno nejlepší optimální nastavení testované dvojice. Z těchto 20 nejlepších kombinací by bylo opět na základě technik vybráno jedno nejlepší optimální nastavení. Při vyhodnocování však došlo k tomu, že každá evaluační technika ukazovala jiné optimální nastavení. Prvotní předpoklad vyhodnocení byl změněn a cílem bylo určení nejlepšího nastavení pro každou evaluační techniku. Tímto způsobem by byla získána čtyři optimální nastavení. I při takovémto vyhodnocování se předpoklad ukázal jako nesprávný, neboť hodnoty parametrů nejlepších kombinací byly napříč celým intervalem zvolených hodnot. Tímto způsobem bylo vyhodnocení v takovém množství hodnot nereálné. Proto konečné vyhodnocení proběhlo na základě Top indexu, který všem čtyřem evaluačním hodnotám přiřkl stejnou významnost.

Optimální nastavení bylo aplikováno na 193 dvojic snímků. Ze získaných hodnot byly vypočteny průměrné hodnoty všech čtyř evaluačních technik.

V této úloze byly zvoleny počáteční hodnoty parametrů dle defaultních hodnot z literatury, nutno však dodat, že informovanost v literatuře o ideálním nastavení parametrů a jejich možných intervalech je velmi omezená. Pokud by testování proběhlo na větším množství dat a s větším počtem vstupních kombinací, bylo by nalezeno nastavení vykazující přesnější výsledky registrace.

Zdrojový kód k úloze byl poskytnutý vedoucím práce a následně upraven. Kód byl naprogramován pro registraci multimodálních snímků i přesto, že se jednalo o snímky monomodální. Ve výše uvedené úloze bylo zadáno šest vstupních parametrů. Při monomodální registraci by parametry byly pouze tři. Dá se předpokládat, že v případě registrace multimodálních snímků pouze s monomodálními parametry, bude registrační proces nepřesný.

Závěr

Bakalářská práce byla zaměřena na zpracování reálných lékařských obrazových dat. V práci byl popsán proces zpracování obrazu a základní principy a metody segmentace obrazu. Především se práce zabývala registrací obrazu, postupem registrace a různými hledisky klasifikace registračních metod. Úkolem práce bylo seznámení s metodami registrace obrazu a jejich následná aplikace. Studováním příslušné literatury bylo zjištěno, že registrace obrazu zahrnuje velmi široký rámec metod, které se v různých kombinacích, v závislosti na typu snímku, jeho výše deformace a následném uplatnění, aplikují na požadované snímky. Vzhledem k těmto poznatkům, není možné použití jedné registrační metody, která by zajistila spolehlivé výsledky při každé implementaci.

Cílem práce byla implementace vybraných nastudovaných metod na reálných obrazových datech. Databáze snímků obsahovala snímky sítnice a především klíčních a stehenních kostí. Veškeré experimenty probíhaly v prostředí MATLAB a numerické výsledky byly vyhodnoceny pomocí excelu.

První testování proběhlo se snímky sítnice. Registrace byla založená na geometrické transformaci, konkrétně rotaci, celého plovoucího snímku. Jednalo se o rigidní typ transformace, která je vhodná pro snímky, jejichž hodnoty intenzity jsou velmi podobné, a zobrazující téměř stejnou scénu. Z výsledků implementace bylo ve většině případů zjištěno, že za účelem dosažení optimálního úhlu registrace nebylo nutné plovoucí snímek vůbec rotovat. Hodnocení podobnosti proběhlo pomocí střední kvadratické chyby a korelačního koeficientu.

Druhé testování bylo provedeno se snímky sítnice, klíčních a stehenních kostí. Na snímky byla aplikována registrace založená na intenzitě a optimalizaci. Cílem bylo nalezení optimální kombinace parametrů vstupních hodnot. Testované kombinace byly vytvořeny v excelu, kde byl vytvořen matematický model tak, aby při zadaném počtu možností vstupních hodnot automaticky vytvořil vstupní kombinace. Bylo provedeno několik testování vstupních kombinací. Z výsledků vyplynuly následující poznatky:

- Parametr $UP = 0$ (false) nelze použít. Jeho použití má za následek nestabilní výsledné hodnoty, protože do výpočtu metriky zahrnuje náhodné množiny pixelů.
- U parametru NSS nebyl prokázán vztah na přesnost výpočtu a zlepšení evaluačních technik.
- Vliv parametru E závisí na velikosti GF a $MaxI$. Ovlivnění výsledku parametrem E při daných GF a $MaxI$ však není pravidelné.
- Dále bylo zjištěno, že čím nižší hodnota parametru E , tím lepší hodnoty evaluačních hodnot.
- Volba vstupních parametrů závisí na podobnosti obrazů. Tím byla potvrzena nastudovaná teorie.

Podobnost byla zaznamenána pomocí střední kvadratické chyby, korelačního koeficientu, strukturální podobnosti a Euklidovské vzdálenosti. Vyhodnocení optimální kombinace vstupních parametrů probíhalo na základě vlastního Top indexu, který významnosti jednotlivých evaluačních technik zahrnul do výpočtu. Výsledné nastavení bylo aplikováno na 193 dvojic snímků, jejichž evaluace nabývaly horších hodnot, než se původně očekávalo.

Na základě zmíněných procedur byly vytvořeny laboratorní úlohy sloužící studentům k pochopení a procvičení procesu registrace obrazu. Úlohy obsahují zjednodušené zadání úkolů praktické části bakalářské práce.

Veškeré výsledné dokumenty, zpracované soubory, pomocné soubory a laboratorní úlohy jsou k bakalářské práci připojeny formou příloh.

Přínosem pokračování práce by byla spolupráce s lékaři a propojení s praxí. Vhodné by bylo zaměření na konkrétní typy snímků a praktické aplikace. Na základě zvolených typů snímků a míře shody mezi nimi, by došlo k optimalizaci kombinací vstupních parametrů. K přesnějšímu určení by přispělo testování většího počtu vstupních kombinací na vyšším počtu snímků.

Seznam literatury

- [1] ŠRÁMEK, J.; RÁČEK, O.; SEDLÁŘ, M. et al. *Získávání a analýza obrazové informace*. In: *Med.muni* [online]. Masarykova univerzita v Brně Lékařská fakulta – Biofyzikální ústav: Masarykova Univerzita v Brně, 2011 [cit. 2020-10-22]. Dostupné z: <https://www.med.muni.cz/biofyz/Image/ucebnice.pdf>
- [2] KUBÍKOVÁ, Kristýna. *Metody detekce hran v biomedicínských obrazech* [online]. Ostrava, 2019 [cit. 2020-10-13]. Dostupné z: <http://hdl.handle.net/10084/136207>. Bakalářská práce. Vysoká škola báňská - Technická univerzita Ostrava.
- [3] HOZMAN, J. *Základní metody předzpracování obrazu*. In: *Praha* [online]. Praha: FEL ČVUT v Praze, - [cit. 2020-10-13]. Dostupné z: http://webzam.fbmi.cvut.cz/hozman/Zprac_obr_prisp_kurz_UEM_3_2003.pdf
- [4] Handbook of Biomedical Image Anylaysia. SURI, J. S., D. L. WILSON a S. LAXMINARAYAN. *Handbook of Biomedical Image Analysis: Volume II: Segmentation Models, Part B*. -. New York: Kluwer Academic / Plenum Publishers, 2005, s. 111-271. ISBN 0-306-48607-9
- [5] FIŘT, J.; HOLOTA, R. Digitalizace a zpracování obrazu. *Digitální mikroskopie a analýza obrazu v metalografii*, 2002.
- [6] FRIBERT, M. *Základy zpracování obrazu*. Pardubice: Univerzita Pardubice, 2006. ISBN 80-7194-901-9.
- [7] HOLČÍK J., *Analýza biologických a klinických dat v mezioborovém pojetí, Vzorkování* [online]. Dostupné z: < <http://www.iba.muni.cz/summer-school2009/res/file/holcikovzorkovani.pdf> > [cit. 2020-10-26]
- [8] BRYJOVÁ, Iveta. Zpracování medicínských a obrazových dat. In: *Repozitář* [online]. Opava: Iveta Bryjová, 2019 [cit. 2020-11-07]. Dostupné z: https://repozitar.cz/repo/37495/Bryjova_Z_M_A_O_D.pdf
- [9] ADAMEC, Václav. *Zpracování a rozpoznávání obrazu* [online]. Olomouc, 2012 [cit. 2020-10-28]. Dostupné z: <<https://theses.cz/id/520eu6/>>. Bakalářská práce. Universita Palackého v Olomouci, Přírodovědecká fakulta. Vedoucí práce Mgr. Eduard Bartl, Ph.D.
- [10] PINKAVOVÁ, Šárka. *Využití metod a dat DPZ při tvorbě KPÚ* [online]. České Budějovice, 2008 [cit. 2020-10-28]. Dostupné z: <<https://theses.cz/id/nm0eti/>>. Diplomová práce. Jihočeská univerzita v Českých Budějovicích, Zemědělská fakulta. Vedoucí práce Ing. Pavel Hánek.
- [11] VAŠATOVÁ, Alena. *Registrace obrazu se zaměřením na biomedicínské aplikace* [online]. Ostrava, 2011 [cit. 2020-10-23]. Dostupné z: <http://hdl.handle.net/10084/87129>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.
- [12] ZANATY, E. A. a S. GHONIEMY. Medical image segmentation techniques: an overview. *International Journal of informatics and medical data processing* [online]. 2016, 2016, 1(1), 16-37 [cit. 2020-11-2]. Dostupné z: https://www.researchgate.net/profile/E-Zanaty/publication/294682473_Medical_Image_Segmentation_Techniques_An_Overview/links/56c2ef9308ae2dc3eb89fb03/Medical-Image-Segmentation-Techniques-An-Overview.pdf

- [13] SANKUR, B. a M. SEZGIN. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging* [online]. 2004, **13**(1), 148-161 [cit. 2020-11-09]. Dostupné z: https://www.researchgate.net/publication/309967669_Image_thresholding_techniques_A_survey_over_categories
- [14] BAŠE, Michal. *Detekce bifurkací cévního řečiště na sítnici* [online]. Brno, 2011 [cit. 2020-11-12]. Dostupné z: <http://hdl.handle.net/11012/513>. Diplomová práce. Vysoké učení technické v Brně. Fakulta elektrotechniky a komunikačních technologií. Ústav biomedicínského inženýrství. Vedoucí práce Radim Kolář.
- [15] BEDNÁŘ, Jan. *Regionální segmentace biomedicínských obrazových dat - laboratorní úloha* [online]. Ostrava, 2019 [cit. 2020-11-12]. Dostupné z: <http://hdl.handle.net/10084/136213>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.
- [16] MAINI, Raman a Dr. Himanshu AGGARWAL. Study and Comparison of Various Image Edge Detection Techniques [online]. , 1-12 [cit. 2020-11-8]. Dostupné z: <http://www.cscjournals.org/manuscript/Journals/IJIP/Volume3/Issue1/IJIP-15.pdf>
- [17] DHAWAN, Atam. Medical image analysis. 2nd ed. Oxford: Wiley-Blackwell, 2011. ISBN 978-047-0622-056.
- [18] KLÁSEK, Pavel. *Segmentace základních částí lidského mozku v MR datech* [online]. Brno, 2012 [cit. 2020-11-13]. Dostupné z: <http://hdl.handle.net/11012/11968>. Bakalářská práce. Vysoké učení technické v Brně. Fakulta elektrotechniky a komunikačních technologií. Ústav biomedicínského inženýrství. Vedoucí práce Miloš Malínský.
- [19] ZOTIN, A.; SIMONOV, K.; KURAKO, M. et al. Edge detection in MRI brain tumor images based on fuzzy C-means clustering. *Procedia Computer Science* [online]. 2018, **126**(-), 1267 [cit. 2020-11-08]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1877050918313474#abs0001>
- [20] VONDRÁK, Ivo. *Umělá inteligence a neuronové sítě*. Ostrava: VŠB - Technická univerzita Ostrava, 1994. ISBN 80-7078-259-5.
- [21] BINI, S. A. Artificial Intelligence, Machine Learning, Deep Learning, and Cognitive Computing: What Do These Terms Mean and How Will They Impact Health Care? *The Journal of Arthroplasty* [online]. 2018, **33**(8), 2358-2361 [cit. 2020-11-12]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0883540318302158>
- [22] HAQUE, I.R.I. a J. NEUBERT. Deep learning approaches to biomedical image segmentation. *Informatics in Medicine Unlocked* [online]. 2020, 2020, **18**(-), [cit. 2020-11-13]. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S235291481930214X#sec1>
- [23] Jiang, F.; Grigorev, A.; Rho, S. et al. Medical image semantic segmentation based on deep learning. *Neural Comput & Applic* **29**, 1257–1265 (2018). <https://doi.org/10.1007/s00521-017-3158-6>
- [24] ZITOVÁ, Barbara a Jan FLUSER. Image registration methods: a survey. *Image and Vision Computing* [online]. 2003, 2003, **21**(-), 977-995 [cit. 2020-11-11]. Dostupné z: <http://library.utia.cas.cz/prace/20030125.pdf>

- [25] MANI, V. R. s a A. SELVARAJ. Survey of medical image registration. *International Journal of Biomedical Engineering and Technology* [online]. 2013, **1**(2), 8-25 [cit. 2020-12-4]. Dostupné z: doi:10.12691/jbet-1-2-1
- [26] Maintz, J. and Viergever. "An Overview of Medical Image Registration Methods." (1998).
- [27] WYAWAHARE, M.V., P.M. PATIL a H.K. ABHYANKAR. Image Registration Techniques: An overview. *International Journal of Signal Processing, Image Processing and Pattern Recognition* [online]. 2009, 2009, **2**(3), - [cit. 2020-11-11]. Dostupné z: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.177.5585&rep=rep1&type=pdf>
- [28] MODERSITZKI, Jan. Numerical methods for image registration. Oxford: Oxford University Press, 2004. Numerical mathematics and scientific computation. ISBN 0-19-852841-8.
- [29] YAMAMURA, Y., H. KIM a A. YAMAMOTO. A Method for Image Registration by Maximization of Mutual Information. - [online]. Korea, 2006, 2006, **18**(21), 1469-1472 [cit. 2020-12-04]. Dostupné z: doi:10.1109/SICE.2006.315301
- [30] M. Su, C. Zhang, Z. Chen and S. Jiang, "Registration of multimodal brain images based on optical flow," *2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*, 2017, pp. 1-5, doi: 10.1109/CISP-BMEI.2017.8302198.
- [31] Velázquez-Durán, M.J., Campos-Delgado, D.U., Arce-Santana, E.R. *et al.* Multimodal 3D rigid image registration based on expectation maximization. *Health Technol.* **10**, 429–435 (2020). <https://doi.org/10.1007/s12553-019-00353-0>
- [32] Z. Yang, N. Kuang, Y.P. Yang, B. Kang, "Brain MR Multimodal Medical Image Registration Based on Image Segmentation and Symmetric Self-similarity," 2020, China, 2020, pp. 1167-1187, doi: 10.3837/tiis.2020.03.014
- [33] Dance, D. R.; Christofides, S; A. D. A. Maidment *et al.* *Diagnostic Radiology Physics-A Handbook for Teachers and Students*. Vídeň : International Atomic Energy Agency, 2014. 978–92–131010–1.
- [34] J. S. Suri, D. Wilson, and S. Laxminarayan. 2005. *Handbook of Biomedical Image Analysis: Volume 3: Registration Models (International Topics in Biomedical Engineering)*. Springer-Verlag, Berlin, Heidelberg, ISBN 978-0-306-48607-4.
- [35] JAN, Jiří. Medical image processing, reconstruction and restoration: concepts and methods. BocaRaton: Taylor & Francis, 2006. Signal processing and communications, 25. ISBN 0-8247-5849-8.
- [36] ZHANG, X., H. DONG, D. GAO a X. ZHAO. A Comparative Study for Non-rigid Image Registration and Rigid Image Registration. In: - [online]. -: -, 2020, 12. 1. 2020 [cit. 2020-12-07]. Dostupné z: <https://arxiv.org/pdf/2001.03831.pdf>
- [37] P. A. van den Elsen, E. -. D. Pol and M. A. Viergever, "Medical image matching-a review with classification," in *IEEE Engineering in Medicine and Biology Magazine*, vol. 12, no. 1, pp. 26-39, March 1993, doi: 10.1109/51.195938.
- [38] K. Sharma and A. Goyal, "Classification based survey of image registration methods," 2013 Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT), Tiruchengode, 2013, pp. 1-7, doi: 10.1109/ICCCNT.2013.6726741.
- [39] Image Registration. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-12]. Dostupné z: <https://uk.mathworks.com/help/images/image-registration.html>

- [40] Approaches to Registering Images. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-12]. Dostupné z: <https://uk.mathworks.com/help/images/approaches-to-registering-images.html>
- [41] Registration Estimator. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-12]. Dostupné z: <https://uk.mathworks.com/help/images/ref/registrationestimator-app.html>
- [42] Techniques Supported by Registration Estimator App. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-12]. Dostupné z: <https://uk.mathworks.com/help/images/techniques-supported-by-registration-estimator-app.html>
- [43] Register Images Using Registration Estimator App. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-13]. Dostupné z: <https://uk.mathworks.com/help/images/register-images-using-the-registration-estimator-app.html>
- [44] Intensity-Based Automatic Image Registration. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-13]. Dostupné z: <https://uk.mathworks.com/help/images/intensity-based-automatic-image-registration.html>
- [45] Create an Optimizer and Metric for Intensity-Based Image Registration. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-13]. Dostupné z: <https://uk.mathworks.com/help/images/create-an-optimizer-and-metric-for-intensity-based-image-registration.html>
- [46] Register Images with Projection Distortion Using Control Points. *Register Images with Projection Distortion Using Control Points* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-14]. Dostupné z: <https://uk.mathworks.com/help/images/registering-an-aerial-photo-to-an-orthophoto.html>
- [47] Find Image Rotation and Scale Using Automated Feature Matching. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-14]. Dostupné z: <https://uk.mathworks.com/help/vision/ug/find-image-rotation-and-scale-using-automated-feature-matching.html>
- [48] Register Multimodal MRI Images. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-15]. Dostupné z: <https://uk.mathworks.com/help/images/registering-multimodal-mri-images.html>
- [49] Common Geometric Transformations. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-15]. Dostupné z: <https://uk.mathworks.com/help/images/geometric-transformations.html>
- [50] Feature Detection and Extraction. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-15]. Dostupné z: <https://uk.mathworks.com/help/vision/feature-detection-and-extraction.html>
- [51] Generic Geometric Transformations. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-15]. Dostupné z: https://uk.mathworks.com/help/images/spatial-referencing.html?s_tid=CRUX_lftnav

- [52] Local Feature Detection and Extraction. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-15]. Dostupné z: <https://uk.mathworks.com/help/vision/ug/local-feature-detection-and-extraction.html>
- [53] Use Phase Correlation as Preprocessing Step in Registration. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-02-15]. Dostupné z: <https://uk.mathworks.com/help/images/use-phase-correlation-as-preprocessing-step-in-registration.html>
- [54] FRISTON, K.J., J.T. ASHBURNER, S.J. KIEBEL a . *Statistical Parametric Mapping: The Analysis of Functional Brain Images* [online]. UK, USA: Elsevier, 2007 [cit. 2021-02-24]. ISBN 978-0-12-372560_8. Dostupné z: https://books.google.cz/books?hl=cs&lr=&id=G_qdEsDlcp0C&oi=fnd&pg=PP1&dq=Statistical+Parametric+Mapping:+The+Analysis+of+Functional+Brain+Images.&ots=XnZLFvR5VF&sig=8g7svqSsLR7DaWGW94GYZsv5Ys0&redir_esc=y#v=onepage&q=interpolation&f=false
- [55] MattesMutualInformation. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-03-03]. Dostupné z: <https://uk.mathworks.com/help/images/ref/registration.metric.mattesmutualinformation.html>
- [56] Styner, M., C. Brechbuehler, G. Székely, and G. Gerig. "Parametric estimate of intensity inhomogeneities applied to MRI." *IEEE Transactions on Medical Imaging*. Vol. 19, Number 3, 2000, pp. 153-165.
- [57] OnePlusOneEvolutionary. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-03-03]. Dostupné z: <https://uk.mathworks.com/help/images/ref/registration.optimizer.oneplusoneevolutionary.html>
- [58] WANG Z.; BOVIK A.C. SHEIKH H.R., and SIMONCELLI E.P., Image quality assessment: From error visibility to structural similarity. *IEEE Trans. Image Processing*, vol. 13, no. 4, pp. 600–612, Apr. 2004 [online]. Dostupné z: <http://www.cns.nyu.edu/~lcv/ssim/>
- [59] Corr2. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-03-01]. Dostupné z: <https://uk.mathworks.com/help/images/ref/corr2.html>
- [60] All about Structural Similarity Index (SSIM): Theory + Code in PyTorch. *Medium* [online]. -: -, - [cit. 2021-03-01]. Dostupné z: <https://medium.com/srm-mic/all-about-structural-similarity-index-ssim-theory-code-in-pytorch-6551b455541e>
- [61] Pdist2. *MathWorks* [online]. United Kingdom: The MathWorks, c1994_2021 [cit. 2021-03-01]. Dostupné z: <https://uk.mathworks.com/help/stats/pdist2.html>
- [62] HUR, J., H. LIM a Ch. PARK et al. Generalized Deformable Spatial Pyramid: Geometry-Preserving Dense Correspondence Estimation. - [online]. 2015, -(-), 1392-1400 [cit. 2021-03-30]. Dostupné z: doi: 10.1109/CVPR.2015.7298745

Seznam příloh bakalářské práce


A.	Laboratorní úlohy	I
B.	Obrazové datasety	II
C.	Zdrojové kódy	V
D.	Výsledky registračních procedur	VI
E.	Pomocné soubory	VII

A. Laboratorní úlohy

Ve složce „Laboratorni_ulohy“ jsou k dispozici tři podsložky s názvem dané laboratorní úlohy. Každá podsložka obsahuje dva soubory formátu .pdf. Jeden soubor slouží jako zadání protokolu, druhý soubor obsahuje kompletně vypracovaný protokol. Ke každé úloze je přidán soubor se zdrojovým kódem spustitelným v MATLABu.

- Laboratorni_ulohy
 - Laboratorni_uloha_rotace
 - Laboratorni_uloha_rotace_zadani.pdf
 - Laboratorni_uloha_rotace_reseni.pdf
 - ZK_rotace.mat
 - Laboratorni_uloha_intenzita
 - Laboratorni_uloha_rotace_zadani.pdf
 - Laboratorni_uloha_rotace_reseni.pdf
 - registracione.mat
 - registerImages.mat
 - grafy.mat
 - Laboratorni_uloha_testovani
 - Laboratorni_uloha_testovani_zadani.pdf
 - Laboratorni_uloha_testovani_reseni.pdf
 - registracione.mat
 - registerImages.mat
 - grafy.mat

B. Obrazové datasety



Obrázek 46: Snímky retiny, první dataset.



a)



b)



c)




d)



e)



f)



g)



h)

Obrázek 47: Snímky retiny, druhý dataset.



a)



b)



c)



d)



e)



f)



g)



h)

Obrázek 48: RTG snímky, třetí dataset.

C. Zdrojové kódy

Složka „Zdrojove_kody“ obsahuje zdrojové kódy, které jsou pro lepší orientaci a pochopení okomentovány.

- Registrace_rotace.mat
- registratione.mat
- registerImages.mat

D. Výsledky registračních procedur

Složka „Vysledky“ zahrnuje dvě hlavní složky s názvem registračních technik, „Vysledky_rotace,“ „Vysledky_intenzita.“ V těchto podsložkách jsou uloženy:

- Vysledky_rotace
 - Grafy+registrace.pdf
 - Promenne
 - Soubory .csv
- Vysledky_intenzita
 - Registrace .png
 - KK (klíční kosti)
 - SK (stehenní kosti)
 - Retiny
 - Soubory .csv
 - Soubory .xlsx

E. Pomocné soubory

Ve složce „Pomocne_soubory“ se nachází excelovské soubory vytvořené pro usnadnění implementace registrace. Jsou zde také zpracované výsledky všech .csv souborů.

- Kombinacni_tabulka.xlsx
- Vysledky.xlsx